



Ricardo Miguel Bairrada Mexia

Licenciado em Engenharia Electrotécnica e de Computadores

Previsão de Produção de Energia Eléctrica através de Fontes de Energia Renováveis

Dissertação para obtenção do Grau de Mestre em
Engenharia Electrotécnica e de Computadores

Orientador : Pedro Pereira, Professor Auxiliar, FCT - UNL

Júri:

Presidente: Doutor João Francisco Alves Martins - FCT/UNL

Arguentes: Doutor Luís Filipe Figueira de Brito Palma - FCT/UNL

Vogais: Doutor Predro Miguel Ribeiro Pereira - FCT/UNL



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Março, 2015

Previsão de Produção de Energia Eléctrica através de Fontes de Energia Renováveis

Copyright © Ricardo Miguel Bairrada Mexia, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objectivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

A todos aqueles que me acompanharam e apoiaram nesta grande jornada.

Ricardo Miguel Bairrada Mexia

Agradecimentos

Em primeiro lugar, gostaria de agradecer ao meu orientador Professor Pedro Pereira por me ter dado a oportunidade de trabalhar neste tema e também por me ter dado a motivação e o apoio necessários em cada uma das fases do projecto.

Agradeço também à Universidade Nova de Lisboa e à Faculdade de Ciências e Tecnologia por me terem acolhido durante estes anos e dado a oportunidade de continuar a minha aprendizagem de forma a preparar-me para a vida profissional e pessoal, com o apoio do corpo docente e de todos os colegas e amigos que me acompanharam nesta jornada.

Aos meus pais e irmão, um especial agradecimento, por me terem proporcionado a possibilidade de estudar na área que mais pretendia, permitindo-me cumprir um dos objectivos de vida, e também por todos os conselhos, apoio e ânimo dados em todos os momentos desta caminhada.

Aos meus familiares por todo o apoio e carinho que sempre me deram ao longo destes anos, o meu agradecimento sincero.

Um especial agradecimento à minha namorada por me ter acompanhado durante estes anos e por me dar força e apoio em todos os momentos do curso, especialmente nos mais difíceis.

Obrigado.

Ricardo Miguel Bairrada Mexia

Terça-feira, 24 de Março, 2015

Abstract

Along the years, the use of renewable energy systems has been increasing and to be able to predict the efficiency that those systems will have, prediction models adapted to each situation are developed.

In the Electrotechnical Engineering Department (DEE) from the Faculty of Sciences and Technology (FCT) there is a PV Solar System and a Wind Power System installed and to estimate the electrical energy produced by them it's proposed in this thesis the development of an electrical energy production prediction model for the installed systems in the department.

In the beginning, to develop the model, the meteorology and energy produced data from 2013 were gathered. After that the data was managed using Java programming language because it wasn't in the best format to be analysed and used to develop the model.

With the data management done, due to the lack of data for the year 2014 to test the model to be created, the meteorology data for 2014 was generated by using the 2013 data. To obtain an approximation of electrical energy produced in 2014 were used the meteorology data from 2014 and approximation surfaces created with the data from 2013.

After having all the necessary data gathered for the development and testing of the prediction model, the data pre-processing was initiated by using filters and the Principal Component Analysis.

In the end, two different structures for the *Artificial Neural Network* (ANN) were created to verify which one was the most adequate for the installed systems.

To validate the developed model, based on ANN, some tests were performed with the 2014 data, different from the data used to create de ANNs.

Concluding with the obtained results, the most adequate filter in the pre-processing is the *Savitzky-Golay* filter and the ANN structure that presented the best results for the model was the ANN with one hidden layer.

KEYWORDS - RENEWABLE ENERGIES, NEURAL NETWORKS, PREDICTIONS, ELECTRIC ENERGY, WEATHER

Resumo

Com o passar do tempo, a aposta em energias renováveis tem vindo a aumentar. De forma a prever o que se irá produzir com os sistemas de energias renováveis, é necessário desenvolver modelos preditivos, específicos para cada situação.

No Departamento de Engenharia Electrotécnica (DEE) da Faculdade de Ciências e Tecnologia (FCT) encontra-se um sistema fotovoltaico e um sistema eólico em funcionamento, e assim de forma a ter uma estimativa da produção de energia de ambos os sistemas, propôs-se nesta dissertação desenvolver um modelo de previsão de produção de energia eléctrica para os sistemas fotovoltaico e eólico.

Para desenvolver o modelo preditivo pretendido, em primeiro lugar recolheram-se os dados meteorológicos e de produção de energia no ano 2013 e realizou-se um processamento desses mesmos dados, com a linguagem de programação Java, uma vez que não se encontravam na melhor forma para serem analisados e utilizados para construção do modelo.

Após realizado o processamento, como os dados do ano de 2014 existentes não eram suficientes para testar o modelo depois de ser desenvolvido, geraram-se dados meteorológicos para 2014 tendo em consideração os dados de 2013. Para os dados de energia produzida, criaram-se superfícies de aproximação a partir dos dados de 2013, e utilizando os dados meteorológicos gerados para 2014 obteve-se uma aproximação da energia produzida.

Tendo todos os dados necessários para a construção do modelo e posteriormente para o testar, iniciou-se o pré-processamento dos dados com recurso a filtros e à Análise em Componentes Principais.

Por fim, construíram-se duas estruturas diferentes de Redes Neurais Artificiais de modo a verificar qual se adequa melhor aos sistemas existentes.

Para validar o modelo construído com base em redes neuronais testou-se o modelo com os dados de 2014, diferentes dos utilizados na sua construção.

Com os resultados obtidos concluiu-se que o filtro mais adequado para o pré-processamento é o filtro *Savitzky-Golay* e a estrutura do modelo mais indicada para o pretendido será a Rede Neuronal Artificial (RNA) com apenas uma camada intermédia.

PALAVRAS-CHAVE - ENERGIAS RENOVÁVEIS, REDES NEURONAIS, PREVISÃO, ENERGIA ELÉCTRICA, METEOROLOGIA.

Índice

Dedicatória	i
Agradecimentos	iii
Abstract	iv
Resumo	vi
Índice	ix
Lista de Figuras	xii
Lista de Tabelas	xiii
Lista de Símbolos e Acrónimos	xv
1 Introdução	1
1.1 Enquadramento	1
1.2 Motivação	2
1.3 Objectivos	2
1.4 Contribuições	3
1.5 Sinopse	3
2 Estado da Arte	5
2.1 Modelos Preditivos	5
2.1.1 Redes Neurais Artificiais (RNA)	6
2.1.2 Modelos Difusos	10
2.1.3 Modelos Estatísticos	13
2.2 Pré e Pós-Processamento de Dados	15
2.2.1 Filtros	17
2.2.2 Normalização de Dados	19
2.2.3 Desnormalização de Dados	19
2.2.4 Análise em Componentes Principais (PCA)	19
2.3 Sinopse	23
3 Metodologia Adoptada	25
3.1 Metodologia	25
3.1.1 Sistema Adoptado	27
3.1.2 Obtenção de Dados	28

3.1.3	Seleção de Dados	31
3.1.4	Definição de Número de Entradas e Saídas	31
3.1.5	Aplicação de Filtro	32
3.1.6	Normalização de Dados Filtrados	33
3.1.7	Análise em Componentes Principais	33
3.1.8	Definição da Estrutura da Rede Neuronal	34
3.2	Sinopse	36
4	Treino e Validação dos Modelos	37
4.1	Método de Validação	37
4.2	Geração de Dados Energéticos para 2014	38
4.3	Resultado dos Dados Filtrados	39
4.4	Resultados Pós-PCA	43
4.5	Treino da Rede Neuronal	44
4.5.1	Uma Camada Intermédia	44
4.5.2	Duas Camadas Intermédias	48
4.6	Teste da Rede Neuronal	50
4.6.1	Uma Camada Intermédia	51
4.6.2	Duas Camadas Intermédias	53
4.7	Sinopse	54
5	Conclusões e Trabalhos Futuros	55
5.1	Conclusões	55
5.2	Trabalhos Futuros	57
	Bibliografia	58

Lista de Figuras

2.1	Estrutura neuronal [1].	7
2.2	Modelo de neurónio artificial [2].	8
2.3	Tipos de Redes Neurais Artificiais	10
2.4	Diagrama de blocos da inferência difusa [3].	11
2.5	Aproximação de uma função através de um conjunto de funções lineares [3]	12
2.6	Sinal sinusoidal sem e com ruído.	16
2.7	Comparações com o sinal pré-processado.	16
2.8	Janela deslizante de um Filtro de Média Móvel [4].	18
2.9	Exemplificações de tipos de PCA [5].	20
2.10	Transformação do PCA [5].	22
3.1	Arquitectura de alto nível.	27
3.2	Reestruturação dos ficheiros de dados.	29
3.3	Leitura da energia produzida.	30
3.4	Superfícies de aproximação.	31
3.5	Obtenção da energia produzida em 2014.	31
3.6	Filtragem dos dados.	33
3.7	Normalização e Análise em Componentes Principais.	34
3.8	RNA com 1 camada intermédia.	35
3.9	RNA com 2 camadas intermédias.	36
4.1	Superfície de aproximação para a energia solar.	38
4.2	Superfície de aproximação para a energia eólica.	39
4.3	Comparação entre diferentes Filtros Passa-baixo de primeira ordem.	40
4.4	Comparação entre diferentes Filtros de Média Móvel.	40
4.5	Comparação entre diferentes Filtros <i>Savitzky-Golay</i> de terceira ordem.	41
4.6	Comparação entre diferentes Filtros <i>Savitzky-Golay</i> de quarta ordem.	41
4.7	Comparação entre os 3 melhores filtros escolhidos.	42
4.8	Porcentagem de informação obtida por número de componentes após o PCA.	43
4.9	Resultado do treino da RNA com 1 camada intermédia (Janeiro) - Performance vs N ^o de Neurónios.	45
4.10	Resultado do treino da RNA com 1 camada intermédia (2013) - 4 ^a semana (1 amostra = 5 minutos).	46

4.11	Resultado filtrado do treino da RNA com 1 camada intermédia (2013) - 4 ^a semana (1 amostra = 5 minutos).	46
4.12	Resultado do Treino da RNA com 2 Camadas Intermédias (2013) - 4 ^a semana (1 amostra = 5 minutos).	48
4.13	Resultado filtrado do treino da RNA com 2 camadas intermédias (2013) - 4 ^a semana (1 amostra = 5 minutos).	49
4.14	Resultado do treino da RNA com 1 camada intermédia (2014) - 4 ^a semana (1 amostra = 5 minutos).	51
4.15	Resultado filtrado do treino da RNA com 1 camada intermédia (2014) - 4 ^a semana (1 amostra = 5 minutos).	51
4.16	Resultado do treino da RNA com 2 camadas intermédias (2014) - 4 ^a semana (1 amostra = 5 minutos).	53
4.17	Resultado filtrado do treino da RNA com 2 camadas intermédias (2014) - 4 ^a semana (1 amostra = 5 minutos).	53

Lista de Tabelas

4.1	Número de componentes com percentagem de informação disponibilizada pelo PCA. . .	44
4.2	Desempenho e correlação mensal dos treinos das RNAs com 1 camada intermédia. . .	47
4.3	Desempenho e correlação mensal dos treinos das RNAs com 2 camadas intermédias. . .	50
4.4	Desempenho e correlação mensal das RNAs com 1 camada intermédia do ano 2014. . .	52
4.5	Desempenho e correlação mensal das RNAs com 2 camadas intermédias do ano 2014. . .	54

Lista de Símbolos e Acrónimos

DEE Departamento de Engenharia Electrotécnica

FCT Faculdade de Ciências e Tecnologia

UNL Universidade Nova de Lisboa

ANN *Artificial Neural Network*

RNA Rede Neuronal Artificial

FIR *Finite Impulse Response*

PCA *Principal Component Analysis*

CSV *Comma-Separated Values*

MSE *Mean Squared Error*

CAPÍTULO 1

Introdução

1.1	Enquadramento	1
1.2	Motivação	2
1.3	Objectivos	2
1.4	Contribuições	3
1.5	Sinopse	3

Durante este capítulo será enquadrada a necessidade que existe em prever a produção de energia eléctrica devido ao seu crescente consumo e produção. Irão também ser referidos quais os motivos e objectivos que levaram à pesquisa e desenvolvimento desta dissertação de mestrado e do algoritmo de previsão de produção de energia eléctrica através de fontes de energia renováveis, e assim como as contribuições que esta pesquisa poderá trazer.

1.1 Enquadramento

Com o passar dos anos devido ao crescimento contínuo da população e consequentemente da necessidade energética, o consumo de energia tem vindo a aumentar. De forma a sustentar esse consumo, e para se diminuir a dependência de recursos fósseis, tem-se recorrido cada vez mais a fontes de energia renováveis. A aposta em energias renováveis é cada vez mais forte em todo o mundo, uma vez que são fontes inesgotáveis de energia e que podem satisfazer a necessidade existente, ao contrário dos recursos fósseis que têm o seu limite.

Como os recursos fósseis são utilizados de forma controlada, ou seja, é possível definir aquilo que se pretende produzir a partir deles, não existe necessidade de prever a produção. Já para os recursos renováveis, devido à imprevisibilidade da meteorologia, torna-se necessário ter modelos de previsão para os sistemas de produção de energia renováveis sendo assim possível estimar quanto se irá produzir num certo intervalo de tempo.

1. INTRODUÇÃO

Para que se possa gerir a produção de energia e também o consumo têm sido criados diferentes tipos de modelos preditivos. Utilizando estes modelos consegue-se prever a energia que se irá consumir ou que será necessária produzir, e também a energia que um sistema irá produzir durante um determinado. Muitas vezes estes modelos preditivos também são utilizados com o objectivo de avaliar a qualidade de um sistema de produção de energia renovável. Quando se pretende instalar um sistema fotovoltaico ou eólico, a previsão de energia é feita para o sistema dimensionado de forma a saber a energia que produzirá nos primeiros anos de funcionamento para que se possa analisar, por exemplo, o tempo de retorno do investimento. No caso abordado nesta dissertação de mestrado, o sistema fotovoltaico e eólico já se encontram instalados no Departamento de Engenharia Electrotécnica (DEE), da Faculdade de Ciências e Tecnologia (FCT), mas para que se possa analisar a eficiência e a produção anual do mesmo, decidiu-se recorrer a um modelo preditivo. Assim torna-se possível realizar uma gestão diferente da energia no departamento, sabendo aproximadamente a quantidade de energia que o departamento tem como garantida durante um ano, de forma a compensar os grandes gastos energéticos causados pelo número de pessoas que frequentam o departamento e principalmente pelos equipamentos existentes utilizados.

1.2 Motivação

Para o desenvolvimento deste projecto no âmbito da unidade curricular de Dissertação de Mestrado teve-se como motivação pessoal o interesse pelas áreas de Energia e de Sistemas, e também a necessidade de prever a produção anual de energia eléctrica dos sistemas fotovoltaico e eólico presentes no Departamento de Engenharia Electrotécnica (DEE) da FCT/UNL. Para a construção deste modelo foram consideradas condições meteorológicas e produções de energias realizadas nos anos anteriores.

1.3 Objectivos

Esta dissertação de mestrado tem como objectivos:

- Realizar um pré-processamento dos dados recebidos da estação meteorológica e dos contadores de energia existentes no DEE, da Faculdade de Ciências e Tecnologia (FCT), da Universidade Nova de Lisboa (UNL);
- Criar um modelo de previsão de produção de energia eléctrica através de Fontes de Energia Renováveis.

De forma a atingir estes objectivos analisaram-se vários tipos de modelos preditivos, que irão ser apresentados no Capítulo 2.1, e após realizada a análise optou-se pelas Redes Neurais Artificiais para a criação do modelo.

1.4 Contribuições

O desenvolvimento de um modelo preditivo, baseado em RNAs, irá contribuir para uma previsão da energia produzida pelos sistemas fotovoltaico e eólico, ao longo de um ano, do Departamento de Engenharia Electrotécnica (DEE) da Faculdade de Ciências e Tecnologia (FCT), da Universidade Nova de Lisboa (UNL), dando a possibilidade de realizar uma melhor gestão de energia no departamento, que realiza grandes gastos energéticos devido aos tipos de equipamentos existentes no mesmo.

1.5 Sinopse

Neste capítulo enquadrou-se a necessidade que existe de gerir a produção de energia eléctrica através de fontes de energia devido ao seu crescente consumo e produção. Foram também referidos quais os motivos e objectivos que levaram à pesquisa e desenvolvimento desta dissertação de mestrado e do algoritmo de previsão de produção de energia eléctrica através de fontes de energia renováveis, e quais as contribuições que esta pesquisa poderá trazer.

1. INTRODUÇÃO

CAPÍTULO 2

Estado da Arte

2.1 Modelos Preditivos	5
2.1.1 Redes Neurais Artificiais (RNA)	6
2.1.2 Modelos Difusos	10
2.1.3 Modelos Estatísticos	13
2.2 Pré e Pós-Processamento de Dados	15
2.2.1 Filtros	17
2.2.2 Normalização de Dados	19
2.2.3 Desnormalização de Dados	19
2.2.4 Análise em Componentes Principais (PCA)	19
2.3 Sinopse	23

Neste capítulo serão abordadas as tecnologias e os métodos utilizados em sistemas de previsão meteorológica e de produção de energia eléctrica através de fontes de energias renováveis. Também serão indicadas algumas aplicações realizadas com esses métodos.

2.1 Modelos Preditivos

O uso de metodologias capazes de criar modelos precisos e robustos têm vindo a ser utilizadas em diferentes áreas, quer para controlo, quer para previsão, tais como a de controlo de sistemas, a previsão de indicadores sócio-económicos, evolução de sistemas, problemas de classificação e também na previsão de produção de energia eléctrica através de fontes renováveis [3].

Para a última área indicada já existem vários tipos de modelos que permitem a previsão de produção de energia eléctrica tais como as Redes Neurais Artificiais (RNA), os Modelos Difusos e os Modelos Estatísticos, os quais irão ser abordados ao longo deste capítulo.

2.1.1 Redes Neurais Artificiais (RNA)

O interesse na utilização de redes neuronais artificiais para a realização da previsão tem aumentado nos últimos anos. Este interesse deve-se essencialmente à sua capacidade de emular a inteligência natural, aprendendo a partir da experiência, isto é, aprendendo uma relação entre as variáveis de entrada e de saída. As redes neuronais artificiais (RNA) são ferramentas que determinam os dados de forma semelhante àquela realizada pelas redes de neurónios biológicos. Por este motivo oferecem uma alternativa na resolução de problemas complexos, são capazes de aprender a partir de exemplos e de lidar com dados incompletos, lidam com problemas não lineares e uma vez treinadas podem realizar previsões e generalizações quase instantaneamente [6].

Estrutura Neuronal

Os neurónios reais são células nervosas fundamentais do sistema nervoso central. Cada pessoa possui mais de cem mil milhões de neurónios no seu sistema, para além de outras tantas células de suporte. A constituição de um neurónio, que é possível observar na Figura 2.1, apresenta quatro partes principais:

- Corpo Celular: Com a forma piramidal (a maioria no neo-cortex) ou esférica, num diâmetro de alguns micrómetros, contém o núcleo no seu interior. O corpo celular executa as transformações bioquímicas necessárias à síntese de moléculas (como as enzimas);
- Dendrites: Arborescência à volta do corpo celular, formada por finas ramificações tubulares, com o diâmetro de alguns décimos de micrómetros. Estes filamentos são os principais detectores de sinais (mensagens) que chegam ao neurónio, a partir dos axónios das células nervosas vizinhas;
- Axónio: Fibra nervosa filaforme, com o comprimento entre o milímetro e mais de um metro, ramificada na extremidade que comunica com outro neurónio. Este filamento longo efectua a transmissão de sinais emitidos pelo neurónio;
- Sinapses: Conexão do axónio de um neurónio à dendrite de outro neurónio, num espaço da ordem de um centésimo de micrómetro. Esta interface sináptica transfere os sinais (mensagens) emitidos pelo neurónio até outro.




Figura 2.1: Estrutura neuronal [1].

As características dos neurónios, além das resultantes de inúmeros pontos comuns com outras células nervosas, garantem cinco funções específicas:

- Entradas: Cada neurónio faz a recepção de sinais provenientes de neurónios vizinhos captados pelas suas dendrites;
- Processamento: Os sinais detectados são integrados num processo conjunto no corpo celular;
- Geração: É gerado um fluxo nervoso que interpreta globalmente as mensagens recebidas e integradas;
- Condução: Esse fluxo nervoso, correspondente a uma mensagem gerada, é comunicada ao longo do axónio;
- Transferência: Os sinais das mensagens geradas e conduzidas são transferidos, por meio das respectivas sinapses, a outros neurónios vizinhos que os possam receber.

As funções específicas realizadas por um neurónio dependem essencialmente de propriedades da membrana externa dos seus componentes estruturais. Na verdade, são cinco as principais funções da membrana no respectivo desempenho:

- **Reacção de mediadores ao nível das dendrites** para detecção das entradas no neurónio;
- **Propagação de impulsos eléctricos ao longo das dendrites** para o corpo celular;
- **Reacção ao nível do corpo celular** relativamente aos impulsos eléctricos fornecidos pelas dendrites, para geração ou não de um novo impulso;
- **Propagação de impulsos eléctricos na extensão do axónio**, referente à mensagem gerada;
- **Libertação de mediadores na extremidade sináptica**, para reconhecimento de outros neurónios aos quais se pode conectar por transferência de mensagens.

A membrana do neurónio serve para manter uma tensão eléctrica (ou diferença de potencial) entre o interior e o exterior do neurónio: em repouso, esta tensão é de -70 mV ; para manter esta tensão, a membrana do neurónio gera certos iões por meio de canais próprios, funcionando como bomba de iões. Podem ser gerados potenciais de acção numa vasta gama de frequências, mas todos com a mesma amplitude: a informação transmitida representa-se por um certo número de potenciais de acção gerados por unidade de tempo, constituindo uma codificação de sinais em frequências [7].

Estrutura de Redes Neuronais Artificiais

Um neurónio artificial é um modelo computacional inspirado em neurónios naturais. Este basicamente consiste em entradas (x_m), como as sinapses de um neurónio natural, que são multiplicadas pelos respectivos pesos (W_{km}), que representam a força do sinal, sendo esse resultado polarizado por b_k e por fim são computorizados por uma função matemática que determina a activação do neurónio ($\varphi(\cdot)$). Outra função computoriza a saída (y_k) do neurónio artificial. As Redes Neuronais Artificiais combinam neurónios artificiais de forma a processar informação [8].

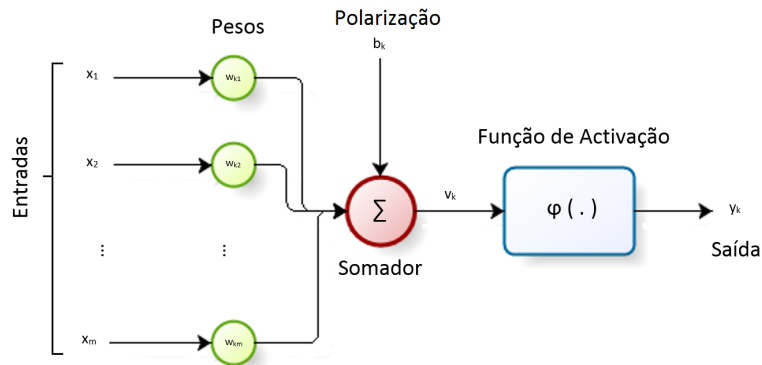


Figura 2.2: Modelo de neurónio artificial [2].

Partindo deste princípio foi estabelecido por Warren McCulloch e Walter Pitts o modelo do neurónio, apresentado na Figura 2.2, com os seguintes elementos fundamentais:

- Entradas: Constituem o vector $x = [x_1, x_2, \dots, x_m]^T$, quer de natureza real, quer binária;
- Pesos de Conexão: Ponderações $w = [w_1, w_2, \dots, w_m]$ positivas nas conexões excitadoras e negativas em conexões inibidoras, sendo nulo o peso quando não existir conexão com o respectivo elemento de processamento;
- Polaridade/Bias: Limiar de activação b_k do elemento de processamento, equivalente a uma entrada $x_0 = 1$ com o peso $w_0 = -b_k$;
- Estado de Activação: Condição $v(x, w)$ de excitação do elemento de processamento conforme a função entre as entradas e os pesos;

- Função de Activação: Relação $\varphi(v)$ que define o comportamento do elemento de processamento em função do seu estado interno total;
- Saída: Resposta $y = \varphi(x, w)$ do neurónio resultante do processamento interno sob excitação das entradas ponderadas.

Numa rede neuronal as entradas excitam vários neurónios, que constituem uma camada: com m elementos de processamento haverá m saídas y_k , para $k = 1, 2, \dots, m$ formando o vector de saída $y = [y_1, y_2, \dots, y_m]$. Assim, cada neurónio k recebe os sinais de entrada x_i , para $i = 1, 2, \dots, m$, com os pesos w_{ki} , quer do ambiente do mundo real, quer de outros neurónios.

Cada elemento de processamento da rede neuronal executa a operação imposta pela função de activação consoante o seu estado interno. No caso mais vulgar o estado interno total corresponde à "combinação linear" das entradas com os pesos

$$v_k = w_{k0}x_0 + w_{k1}x_1 + \dots + w_{km}x_m \quad (2.1)$$

e como $x_0 = 1$ ainda se escreve $v_k = \sum_{i=1}^m w_{ki}x_i + b_k$, onde o peso de polaridade b_k traduz a "deslocação de origem" da função de activação e daí a designação de "polaridade" do elemento de processamento. Assim a saída será:

$$y_k = \varphi(\sum_{i=1}^m w_{ki}x_i) \quad (2.2)$$

Ou ainda, utilizando,

$$y_k = \varphi(w_k x) \quad (2.3)$$

Com o vector linha w_k e o vector coluna x [7].

Topologia de Redes Neurais Artificiais

As redes neurais podem ser classificadas, como se pode ver na Figura 2.3, quanto à acronia do sistema, pelo número de elementos processadores em camadas:

- Rede Neuronal Monocamada (*Single-Layer*): Dispõe de uma única camada, com os elementos processadores "completamente intraconectados" ou "parcialmente intraconectados". Foi o primeiro modelo concebido, baseado no *perceptrão*, que revelou limitações de cálculo e veio a suscitar o desenvolvimento de sistemas com mais camadas interconectadas;
- Rede Neuronal Multicamada (*Multi-Layer*): Possui duas ou mais camadas de elementos processadores interconectados (podendo existir eventuais intraconexões), sendo uma camada de entrada

situada num extremo da rede, com várias camadas escondidas, que se encontram no interior da rede, e uma cada de saída, colocada no outro extremo da rede neuronal. No caso mais simples da dupla camada não há qualquer camada escondida.

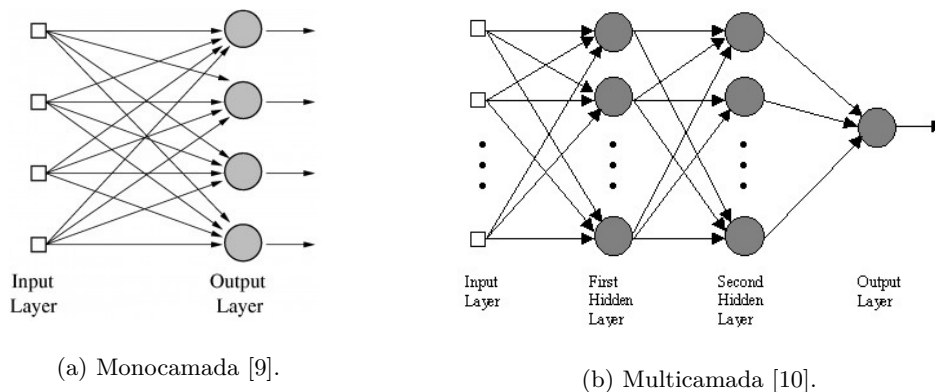


Figura 2.3: Tipos de Redes Neuronais Artificiais

Também é possível definir uma Rede Neuronal Artificial em relação aos sentidos de orientação das interconexões:

- Rede Neuronal Proactiva (*Feed-Forward*): As conexões entre camadas têm o único sentido da entrada para a saída, dependendo os valores das saídas apenas das entradas e dos pesos atribuídos a essas conexões, consoante a função de activação. Tratando-se de um controlo neuronal em anel aberto, resulta sempre numa rede estável;
- Rede Neuronal Retroactiva (*Feed-Back*): Além das conexões proactivas, a rede neuronal contém também conexões retroactivas, isto é, de um elemento processador de uma camada para os elementos processadores da camada anterior, de onde resulta um controlo neuronal em anel fechado. Também se designa como "Rede Neuronal Recorrente" porque o processo retroactivo é repetitivo [7].

2.1.2 Modelos Difusos

No último quarto do século XX, nasceram os sistemas difusos e com o passar do tempo foi sendo cada vez mais aplicado industrialmente. As múltiplas vantagens que apresenta, sobretudo como metodologia não linear e adaptativa, são bastante significativas para justificar mais investigação científica, alicerçada na lógica difusa e na teoria das possibilidades.

Os sistemas difusos assentam na extensão da lógica booleana, onde apenas intervêm os conceitos de "verdadeiro" ou "falso", para uma lógica difusa em que participa um certo "grau" de verdade ou de falsidade. Neste contexto, adquirem importância termos aproximativos de natureza vaga, como "pequeno" ou "grande". Assim, tende-se a exprimir raciocínios mais próximo dos praticados pelos seres

humanos, que não se limitam a afirmações crispadas, como "sim" e "não", mas admitem igualmente válidas ilações intermédias, do género "talvez" ou "assim assim" [11].

O principal objectivo de um modelo difuso é descrever um determinado sistema a partir de condições do seguinte tipo:

$$\text{If } u \text{ is } A_i \text{ then } y \text{ is } B_i \quad (2.4)$$

Onde A_i são antecedentes e B_i são consequentes que correspondem aos termos linguísticos para as i regras existentes, sendo u e y respectivamente as variáveis de entrada e saída, podendo estas serem linguísticas ou valores *singleton*.

Este tipo de modelo caracteriza-se por conseguir descrever um sistema com incerteza associado a ele, por exemplo muito frio ou muito quente, tornando o problema num problema qualitativo em vez de quantitativo, sendo as suas variáveis representadas por conjuntos difusos.

Os conjuntos diferem dos conjuntos clássicos (conjuntos binários) pelo facto de uma certa variável poder pertencer a um intervalo, que normalmente varia entre 0 e 1, em vez de só poder tomar dois valores, 0 e 1, numa classificação de verdadeiro ou falso.

É através dos modelos difusos que a saída é gerada a partir das entradas, através da utilização da lógica difusa. Este é composto por filtros, que no caso dos sistemas dinâmicos são filtros dinâmicos, gerando atrasos nas entradas e nas saídas, por um fuzzificador que transforma os dados numéricos em dados difusos e pelo correspondente desfuzzificador que volta a transformar os dados em dados numéricos. Para além das operações já referidas, este também é composto pelo núcleo principal onde se realiza a inferência difusa que envolve a utilização de funções de pertença, operadores lógicos e regras do tipo *If-Then*.

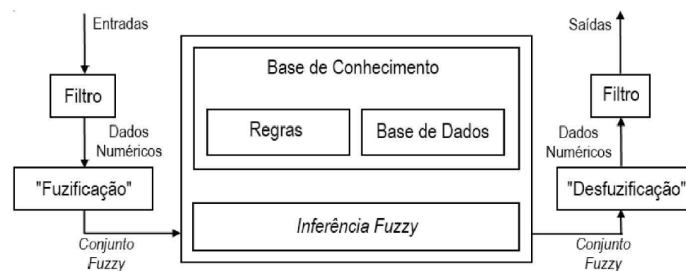


Figura 2.4: Diagrama de blocos da inferência difusa [3].

Essa inferência pode ser realizada através de quatro abordagens diferentes:

- Modelo Linguístico Difuso: Este modelo é caracterizado pelos termos linguísticos, quer os antecedentes quer os consequentes, serem sempre conjuntos difusos, podendo o mesmo acontecer com as variáveis, sendo preciso proceder à desfuzzificação da saída;

- Modelo Singleton: Um modelo do tipo *Singleton* é um caso especial do modelo anterior, sendo os consequentes, B_i , valores discretos;
- Modelo Relacional Difuso: Este tipo de modelo cria associações entre antecedentes e consequentes através de relações difusas;
- Modelo Difuso Takagi-Sugeno: O modelo difuso do tipo *Takagi-Sugeno*, que será apresentado de seguida, difere dos modelos linguísticos e dos relacionais pelo facto da saída ser determinística. As funções de pertença dos termos consequentes são aproximadas através de funções lineares:

$$\text{If } u \text{ is } A_i \text{ then } y_i \text{ is } a_i^T u + b_i \quad (2.5)$$

Onde a_i é um parâmetro de u , que é a entrada do modelo, e b_i o seu *offset*, como se pode observar na Figura 2.5.

Na figura 2.5 é possível observar um exemplo do modelo difuso *Takagi-Sugeno*.




Figura 2.5: Aproximação de uma função através de um conjunto de funções lineares [3]

Para sistemas dinâmicos, a metodologia é idêntica à que foi descrita até agora, sendo aplicado um modelo do tipo entrada-saída. Em particular para um modelo do tipo *Takagi-Sugeno*, o modelo difuso toma a seguinte forma:

$$\begin{aligned} &\text{If } (y(k) \text{ is } A_{i1} \text{ and } y(k-1) \text{ is } A_{i2} \text{ and } y(k-n_y+1) \text{ is } A_{in_y}) \\ &\text{and } (u(k-n_k) \text{ is } B_{i1} \text{ and } u(k-1-n_k) \text{ is } B_{i2} \text{ and } u(k-n_u-n_k+1) \text{ is } A_{in_u}) \\ &\text{then } y(k+1) = \sum_{j=1}^{n_y} a_{ij}y(k-j+1) + \sum_{j=1}^{n_u} b_{ij}u(k-j+1) + c_i \end{aligned} \quad (2.6)$$

Em que n_y corresponde aos atrasos na saída, n_u aos atrasos nas entradas e n_k aos atrasos puros, sendo este modelo do tipo NARX, que se trata de um sistema não linear auto-regressivo com variável exógena [3].

2.1.3 Modelos Estatísticos

Para a previsão de produção de energia eléctrica existem diferentes modelos estatísticos. Este tipo de modelos são essencialmente baseados em dados de observação no local de interesse. Para a previsão de produção de energia eólica os dados de observação usados seriam a velocidade do vento W_{obs} e a potência eólica P_{wobs} [1]. Para a previsão de energia solar produzida, os dados de observação usados seriam a radiação solar R_{obs} , a temperatura T_{obs} e a potência solar P_{sobs} . Um conjunto de dados de longa data permite descodificar a relação existente entre as condições meteorológicas e a energia produzida, tanto eólica como solar. Desta forma, a produção actual é contabilizada e certos factores que interferem na eficiência do sistema, como por exemplo características do local, que não são tidas em conta nas curvas características calculadas pelos fabricantes em condições de laboratório ideais, são consideradas.

Inicialmente, a partir do uso de métodos de regressão estatística, uma variedade de modelos é ajustada aos dados existentes. Numa segunda fase, depois dos dados meteorológicos serem filtrados, estes são utilizados para estimar a potência de saída dos sistemas de produção.

Com esta estrutura existem diferentes categorias de modelos para estimativa de potência eólica, tais como:

- Estimativa por Regressão Polinomial;
- Estimativa baseada na Curva de Potência;
- Estimativa baseada em Equações Não-Polinomiais.

De seguida irão ser descritos cada um dos tipos de estimativas indicados [12].

Estimativa por Regressão Linear

Um dos métodos básicos para previsão de potência eólica gerada é a descrição da produção de energia de uma turbina como uma função cúbica da velocidade do vento. Esta abordagem é equivalente à proposta por [11], em que se estima a energia produzida ao aplicar múltiplos métodos de regressão na velocidade do vento prevista e na potência medida na turbina:

$$P_{t+k} = a_k W_{t+k} + b_k W_{t+k}^2 + c_k W_{t+k}^3 + d_k P_t + l_k + e_{t+k} \quad (2.7)$$

Onde P_{t+k} é a potência eólica prevista, W_{t+k} é a velocidade do vento prevista, P_t a potência obtida na amostra anterior e a, b, c, d, e, l são os pesos variáveis correspondentes.

Uma abordagem mais simples é a aplicação da equação 2.7 mas sem se considerar a amostra anterior da potência:

$$P_{t+k} = a_k W_{t+k} + b_k W_{t+k}^2 + c_k W_{t+k}^3 + l_k + e_{t+k} \quad (2.8)$$

Este esquema pode obter diferentes pesos estatísticos dependendo dos valores da velocidade do vento, uma vez que este tipo de equação não-linear apresenta um comportamento variável para diferentes escalas de valores de entrada [12].

Estimativa baseada na Curva de Potência

A implementação da curva característica descrita é muito utilizada em aplicações de previsão potência e fornece uma ferramenta segura ao converter a velocidade do vento em potência eléctrica. Cada turbina eólica tem uma curva característica associada que descreve o processo ideal de conversão de energia cinética da velocidade do vento em potência eléctrica. A forma da curva característica é semelhante para diferentes tipos de turbinas eólicas e é fornecida pelo fabricante através de calibrações realizadas em condições laboratoriais idênticas às reais.

De forma a formular a correspondência da velocidade do vento e da potência eólica de saída, dois aspectos são tidos em consideração: a correlação entre a velocidade do vento e a potência eólica tal como especificada pelo fabricante e a expressão teórica da potência disponível descrita pela equação $P = 0,5\rho_{air}A_ru^3$, notando que a potência disponível P no fluxo corrente livre de vento é uma função cúbica da velocidade do vento u , onde A_r é a área do rotor exposta ao vento e ρ_{air} a densidade do ar. No caso que se irá descrever depois de descritos os tipos de estimativas, os valores da curva característica foram adaptados a uma função polinomial cúbica de forma a evitar descontinuidades.

Tendo em conta que a produção de energia depende do desempenho da turbina eólica, foram adoptadas duas equações matemáticas.

A primeira expressa a potência providenciada P_{t+k} como uma linearidade análoga da potência obtida da curva característica $po(W_{t+k})$:

$$P_{t+k} = a \cdot po(W_{t+k}) + e \quad (2.9)$$

Uma forma relativa da equação anterior apresentada pode ser obtida ao adicionar um termo extra que indique que a potência providenciada P_{t+k} é relacionada com a potência de saída numa amostra anterior [12]:

$$P_{t+k} = a \cdot po(W_{t+k}) + b \cdot P_t + e \quad (2.10)$$

Estimativa baseada em Equações Não-Polinomiais

Um problema típico dos modelos preditivos anteriores é a previsão da forma não-linear das curvas de potência obtidas que é muito sensível às variações do vento. Esta sensibilidade não pode ser facilmente capturada por modelos polinomiais. Uma forma de resolver este problema é proposta em [1], em que se adaptam funções hiperbólicas não-lineares que contêm termos trigonométricos e que descrevem correctamente comportamentos não-lineares, tal como a dependência que a potência de saída tem da velocidade do vento.

Na presente abordagem, é focada a relação não-linear entre a velocidade do vento e a potência eólica produzida. Mais precisamente, a função tangente hiperbólica é utilizada num modelo da seguinte forma:

$$P_{t+k} = a_0 \cdot \tanh\left(\frac{W_{t+k} - a_1}{a_2}\right) + a_3 \quad (2.11)$$

Onde P_{t+k} é a potência eólica produzida, W_{t+k} é a velocidade do vento e a_i são os coeficientes de regressão que representam um significado físico específico: a_0 é o factor de escala da curva, a_1 descreve o alcance do eixo horizontal onde a variação da curva ocorre, e a_3 é o termo de correcção.

Uma forma alternativa do modelo anterior pode ser uma alteração ao se adicionar um termo extra P_t que é a potência obtida na amostra anterior [12]:

$$P_{t+k} = a_0 \cdot \tanh\left(\frac{W_{t+k} - a_1}{a_2}\right) + a_3 + b \cdot P_t \quad (2.12)$$

2.2 Pré e Pós-Processamento de Dados

Inicialmente, antes de qualquer utilização dos dados para desenvolver o projecto, é necessário a realização de um pré-processamento uma vez que nem sempre se encontram no melhor formato para a sua utilização.

Por exemplo, considerando um sinal sinusoidal com e sem ruído, como mostra a figura 2.6, é possível verificar que o sinal com ruído está muito distorcido comparado com o original. Em sinais como estes é necessário suavizá-los de forma a que se perceba pelo menos o padrão/formato do sinal em questão para que possa ser trabalhado da melhor forma.




Figura 2.6: Sinal sinusoidal sem e com ruído.

Ao realizar o pré-processamento do sinal utilizando um filtro, é possível recuperar parte do padrão/formato do sinal. Como se pode observar na figura 2.7, realizando um pré-processamento como este obtém-se um sinal muito semelhante ao original, com o qual será muito mais fácil trabalhar.




Figura 2.7: Comparações com o sinal pré-processado.

Depois de desenvolvido o projecto e de obtidos os resultados pretendidos também é necessário a realização de um pós-processamento dos dados para que possam voltar às suas condições iniciais mantendo esses mesmos resultados. Nesta secção irão ser referenciados três tipos de filtros, o Filtro Passa-baixo de 1ª Ordem, o Filtro de Média Móvel e o Filtro *Savitzky-Golay* e também a metodologia de Análise em Componentes Principais (PCA).

2.2.1 Filtros

Muitas vezes devido à existência de ruído num conjunto de dados é necessário a utilização de filtros para o eliminar uma vez que poderá influenciar os resultados dos modelos que não respondem bem a dados com altas frequências, tal como é caso das redes neuronais.

Filtro Passa-baixo de 1^a Ordem

O Filtro Passa-baixo de 1^a Ordem, que também é conhecido como sendo um filtro de média móvel pesado exponencialmente, é um filtro simples que permite a redução de ruído existente num determinado conjunto de dados. Com este tipo de filtro consegue-se suavizar o sinal usando a seguinte equação:

$$y(k) = \alpha y(k-1) + \beta x(k) \quad (2.13)$$

Onde as variáveis α e β são constantes, $y(k-1)$ corresponde à amostra anterior do sinal $x(k)$ filtrado, $y(k)$.

Para que o filtro funcione da maneira pretendida é necessário considerar $\alpha = 1 - \beta$, e quanto mais perto a constante α estiver da unidade, maior será o efeito do filtro [13].

É possível observar-se o resultado do uso de um filtro deste tipo na Figura 2.7.

Filtro de Média Móvel

O Filtro de Média Móvel é usado com o objectivo de reduzir o ruído existente no conjunto de dados. Para que tal seja possível este filtro calcula a média das amostras existentes mas considerando um conjunto específico, conhecido como janela deslizante, como se pode ver na Figura 2.8. Este procedimento é repetido para que a janela deslizante de M amostras seja usado para calcular a média de todo o conjunto de dados que se pretendem filtrar.

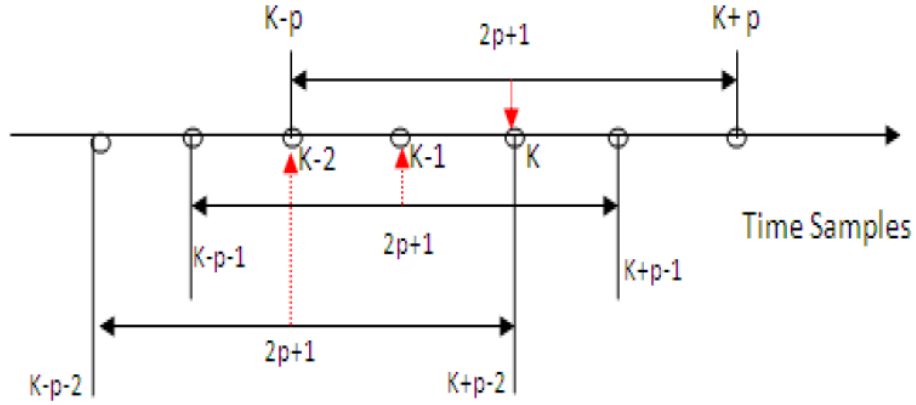


Figura 2.8: Janela deslizante de um Filtro de Média Móvel [4].

O sinal filtrado é dado por (2.14), [4]:

$$y(k) = \frac{1}{M} \sum_{m=k-p}^{k+p} x(m) \quad (2.14)$$

Filtro *Savitzky-Golay*

Tal como os filtros indicados anteriormente, o Filtro *Savitzky-Golay* tem como objectivo suavizar os sinais atenuando as altas frequências e o ruído dos mesmos, mas de uma forma diferente. Por vezes, utilizando os tipos de filtros referenciados, ao tentar-se reduzir grande parte do ruído existente acaba-se por perder dados importantes do sinal desejado. Por exemplo, se existirem alguns picos relativamente estreitos no sinal a filtrar, correspondentes às frequências mais altas do mesmo, e se o comprimento do filtro for muito maior que a duração dos picos, então o filtro tenderá a suavizar em demasia o sinal perdendo-se assim parte do formato do sinal.

O Filtro *Savitzky-Golay*, também conhecido por *polynomial smoothing or least-squares smoothing filter*, é uma generalização dos filtros de média *Finite Impulse Response* (FIR) que consegue preservar melhor o conteúdo de altas frequências do sinal desejado, não removendo tanto ruído como o filtro de média. Para tal, este tipo de filtro realiza a aproximação ideal de um conjunto de amostras utilizando polinómios de diferentes graus [13]. O sinal obtido a partir do Filtro *Savitzky-Golay* é dado pela seguinte fórmula matemática:

$$y(k) = \sum_{m=-M}^M b_0(m) x(k+m) \quad (2.15)$$

Onde b_0 é conhecido como filtro *Savitzky-Golay* de estado estacionário e transiente [13], que contém um conjunto de coeficientes que preservam os momentos altos do sinal [14], M é o tamanho da janela

de amostras em que o filtro irá ser aplicado, e x é a sequência de amostras com ruído que se pretende filtrar [13].

2.2.2 Normalização de Dados

Quando se consideram diversas variáveis num determinado processo, e estas não variam na mesma ordem de grandeza, é necessário recorrer à normalização dos mesmos. Caso não se normalizem os dados, o modelo utilizado poderá dar um maior ou menor peso a certas variáveis que podem influenciar os resultados desse modelo.

Para que tal não aconteça, os dados que se pretendem normalizar são convertidos para magnitudes entre -1 e 1 ou entre 0 e 1. Assim todas as variáveis utilizadas estarão a variar na mesma ordem de grandeza.

A fórmula matemática a partir da qual se realiza a normalização é a seguinte:

$$x_{norm} = l_{min} + (l_{max} - l_{min}) \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.16)$$

Onde l_{min} e l_{max} são os limites entre os quais se pretende obter a normalização, x_{min} e x_{max} representam o valor mínimo e máximo do vector x a normalizar [3].


2.2.3 Desnormalização de Dados

Depois de obtidos os resultados a partir do modelo construído, por vezes, desnormalizam-se os dados de forma a obter os resultados nas unidades originais para que se possa ter uma melhor ideia da energia que se irá produzir.


Assim para se obter os resultados nos intervalos originais, inverte-se a equação 2.16 referenciada na secção anterior [3].

2.2.4 Análise em Componentes Principais (PCA)

A Análise em Componentes Principais é considerada um procedimento estatístico que se foca em elucidar uma estrutura covariante de um conjunto de variáveis, ou seja, permite identificar as direcções principais em que as amostras variam.



(a) PCA por representação de dados (2D).



(b) PCA por redução de dimensões (1D).

Figura 2.9: Exemplificações de tipos de PCA [5].

Se há variação dos valores do conjunto de dados seja por causas naturais ou erros experimentais aleatórios, então espera-se que esse conjunto seja normalmente distribuído. Nesse caso, é possível mostrar uma extensão nominal da distribuição normal por uma hiper-elipse, como se pode verificar na figura 2.9 (a). A hiper-elipse junta amostras que se consideram pertencentes a uma classe. É desenhada até uma distância em que a probabilidade de uma amostra pertencer a essa classe é baixa.

Caso a variação dos valores do conjunto de dados tenha outras causas, então o *Principal Component Analysis* (PCA) realiza uma redução da dimensão do conjunto de dados ao qual se aplica o processo. Considerando duas variáveis que se encontrem, aproximadamente, relacionadas linearmente como mostra a figura 2.9 (b), e também considerando o plano de eixos que se apresenta na figura 2.9 (a), como a variação dos dados é representada principalmente pelo eixo U e a variação ao longo do eixo V é muito próxima de zero então é possível passar a considerar um sistema apenas com o eixo U, em vez dos dois, reduzindo e simplificando o conjunto de dados.

Em termos matemáticos, as componentes principais são obtidas ao se calcular os vectores e valores próprios da matriz de covariância dos dados. Este processo é equivalente a encontrar um novo sistema de eixos em que a matriz de covariância é diagonal. O vector próprio com o maior valor próprio é a direcção com a maior variação, ou seja, passa a ser a direcção principal (eixo U), e o vector próprio com o segundo maior valor é a direcção ortogonal com a segunda maior variação, ou seja, passa a ser o eixo secundário (eixo V). Definindo A como sendo uma matriz de dimensão $n \times n$, os valores de A são dados pelas raízes de:

$$\det(A - \lambda I) = |(A - \lambda I)| = 0 \quad (2.17)$$

Onde I é uma matriz identidade $n \times n$. Esta equação tem o nome de equação característica e tem n raízes. Tendo A o valor próprio λ , então existe um vector tal que:

$$Ax = \lambda x \quad (2.18)$$

O vector x é o vector próprio de A associado ao valor próprio λ . É possível observar que não existe uma solução única para x na equação anterior. É apenas um vector direcional e pode ter qualquer magnitude. Para se encontrar uma solução numérica para x é necessário atribuir um valor arbitrário a um dos seus elementos, por exemplo 1, o que dará um sistema de equações que permitirá obter os restantes elementos do vector. Caso não haja uma solução, repete-se o processo com outro elemento. Após obtida a solução, esta é normalizada de forma a que x tenha comprimento 1, isto é $x \cdot x^T = 1$. Por exemplo, supondo que se tem uma matriz A 3×3 com os vectores próprios x_1, x_2, x_3 e valores próprios $\lambda_1, \lambda_2, \lambda_3$ tem-se:

$$Ax_1 = \lambda_1 x_1 \quad Ax_2 = \lambda_2 x_2 \quad Ax_3 = \lambda_3 x_3 \quad (2.19)$$

Colocando os vectores próprios como colunas de uma matriz fica-se com:

$$A \begin{bmatrix} x_1 & x_2 & x_3 \end{bmatrix} = \begin{bmatrix} x_1 & x_2 & x_3 \end{bmatrix} \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \quad (2.20)$$

Considerando:

$$\Phi = \begin{bmatrix} x_1 & x_2 & x_3 \end{bmatrix} \quad \Lambda = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \quad (2.21)$$

Obtém-se a equação de matrizes:

$$A \Phi = \Phi \Lambda \quad (2.22)$$

Normalizam-se os vectores próprios, sendo eles ortogonais, portanto:

$$\Phi \Phi^T = \Phi^T \Phi = I \quad (2.23)$$

O que significa que:

$$\Phi^T A \Phi = \Lambda \quad (2.24)$$

E:

$$A = \Phi \Lambda \Phi^T \quad (2.25)$$

2. ESTADO DA ARTE

Considerando agora que isto se aplica à matriz de covariância no processo PCA, sendo Σ uma matriz de covariância $n \times n$, existe uma matriz ortogonal Φ $n \times n$ cujas colunas são os vectores próprios de Σ , e uma matriz diagonal Λ cujos elementos diagonais são os valores próprios de Σ , tal que:

$$\Phi^T \Sigma \Phi = \Lambda \quad (2.26)$$

Desta forma é possível afirmar que a matriz de vectores próprios ϕ se trata de uma transformação linear que, como mostra a figura 2.9 (a), transforma as amostras do sistema de eixos $[X, Y]$ para os eixos $[U, V]$. Generalizando, a transformação linear dada por Φ , transforma as amostras num conjunto de dados onde as variáveis não estão correlacionadas. A matriz de correlação dos dados no novo sistema de coordenadas é Λ que tem zeros em todos os elementos não diagonais.




Figura 2.10: Transformação do PCA [5].

Para que se possa perceber o funcionamento do PCA na prática é necessário observar e analisar a figura 2.10. A figura 2.10 apresenta uma ilustração geométrica do processo em duas dimensões. Ao usar todas as amostras é possível encontrar os valores médios das variáveis (μ_{x1}, μ_{x2}) e a matriz de covariância Σ que neste caso é uma matriz 2×2 .

Ao se calcularem os vectores próprios da matriz de covariância obtêm-se as direcções dos vectores que são indicadas por ϕ_1 e ϕ_2 . Depois, ao colocar os dois vectores próprios como colunas na matriz $\Phi = [\phi_1, \phi_2]$ cria-se a matriz de transformação que converte as amostras do sistema de eixos $[x_1, x_2]$ para o sistema de eixos $[\phi_1, \phi_2]$ a partir da equação 2.27.

$$p_\phi = (p_x - \mu_x) \cdot \Phi \quad (2.27)$$

Onde p_x é qualquer amostra do sistema de eixos $[x_1, x_2]$, $\mu_x = (\mu_{x1}, \mu_{x2})$ é o ponto médio dos dados, e p_ϕ é a coordenada no sistema de eixos $[\phi_1, \phi_2]$ [5].

2.3 Sinopse

Neste capítulo foram abordadas tecnologias e métodos utilizados em sistemas de previsão meteorológica e de produção de energia eléctrica através de fontes de energias renováveis. Também foram indicadas as aplicações realizadas com esses métodos.

2. ESTADO DA ARTE

CAPÍTULO 3

Metodologia Adoptada

3.1	Metodologia	25
3.1.1	Sistema Adoptado	27
3.1.2	Obtenção de Dados	28
3.1.3	Seleção de Dados	31
3.1.4	Definição de Número de Entradas e Saídas	31
3.1.5	Aplicação de Filtro	32
3.1.6	Normalização de Dados Filtrados	33
3.1.7	Análise em Componentes Principais	33
3.1.8	Definição da Estrutura da Rede Neuronal	34
3.2	Sinopse	36

Neste capítulo será abordado o processo realizado ao longo da dissertação, tal como o sistema adoptado. Também será descrito e exemplificado na forma de diagramas cada uma das fases no desenvolvimento do algoritmo para previsão de produção.

3.1 Metodologia

Como já foi referenciado no Capítulo 1.3, o objectivo desta dissertação é criar um modelo que permita a previsão de produção de energia eléctrica através de fontes de energia renováveis, mais precisamente energia solar e eólica. Para que esse objectivo seja alcançado é necessário passar por várias etapas.

A primeira etapa consiste na recolha de dados a partir dos quais se irá criar o modelo preditivo. Os dados recolhidos são as condições meteorológicas existentes, no espaço de 1 ano, no local em que o sistema considerado está situado. As condições são obtidas a partir da estação meteorológica junto ao sistema de produção, e estas são a Radiação Solar, a Temperatura, a Velocidade do Vento, a Direcção

3. METODOLOGIA ADOPTADA

do Vento e a Velocidade das Rajadas de Vento. Os dados meteorológicos relacionados com o vento são obtidos a partir de um Anemómetro *Davis Cup*, a Temperatura é obtido a partir de um termómetro situado na estação meteorológica e a Radiação Solar é obtida a partir de um piranómetro PYR.

Após a recolha dos dados necessários para a construção do modelo preditivo, a primeira questão colocada é:

- Quais as variáveis a considerar, fornecidas pela estação meteorológica, que afectam mais a produção de energia eléctrica ao longo do tempo?

Para responder a esta pergunta analisou-se cada uma das variáveis de forma a ver quais delas teriam um padrão constante ao longo do ano. Depois de se analisar uma a uma optou-se por se considerar todas as variáveis indicadas anteriormente à excepção da Velocidade das Rajadas de Vento, visto que esta tem um padrão muito semelhante ao da Velocidade do Vento, e evitando assim informação aproximadamente duplicada.

Após escolhidas as variáveis de entrada para construção do modelo preditivo é necessário tratar essa informação. Para tal, uma vez que os dados existentes apresentam frequências muito elevadas e que poderá ser prejudicial para o comportamento do modelo, irá ser criado um filtro que reduza as frequências dos mesmos para que o modelo tenha uma menor dificuldade em aprender.

Com os dados suavizados, com o uso do filtro, uma das coisas que fica a faltar é a redução dos limites mínimos e máximos dos valores das variáveis, ou seja, passá-las de um intervalo, por exemplo, entre 0 e 1000 para um intervalo entre 0 e 1. Para que tal seja possível normalizam-se todas as variáveis escolhidas que afectam a produção energética do sistema, uma vez que os modelos preditivos descritos no estado de arte trabalham com as entradas normalizadas.

Após se realizar a filtragem e a normalização dos dados que se pretendem usar como entradas, a questão que se coloca é:

- Quais e quantos são os atrasos considerados nas variáveis de entrada do modelo?

De forma a responder a esta pergunta foi necessário realizar alguma pesquisa sobre previsão meteorológica. De acordo com o documento [15], para o planeamento de recursos é necessário considerar no mínimo uma semana. Sabendo isto, consideram-se 7 atrasos em que o maior atraso varia de 1 a 3 semanas.

Sabendo o número de variáveis (4) e o número de atrasos por cada variável (7) foi possível concluir que o número de entradas do modelo era muito elevado (32). Para que se pudesse reduzir esse valor e também o número de amostras por variável aplicou-se o processo estatístico PCA, descrito no estado de arte, que permite reduzir esse número.

Por fim, com o número de variáveis e atrasos definidos a utilizar no modelo, a última questão que se coloca é:

- Qual o tipo de modelo preditivo a utilizar para a previsão de produção de energia eléctrica?

De forma a escolher uma opção, analisaram-se os modelos preditivos descritos no estado de arte e optou-se pelas Redes Neurais Artificiais devido à sua eficácia para as variações dos valores das amostras meteorológicas.

3.1.1 Sistema Adoptado

O sistema que se decidiu adoptar, consoante o que foi descrito anteriormente no Processo, está presente na figura 3.1.

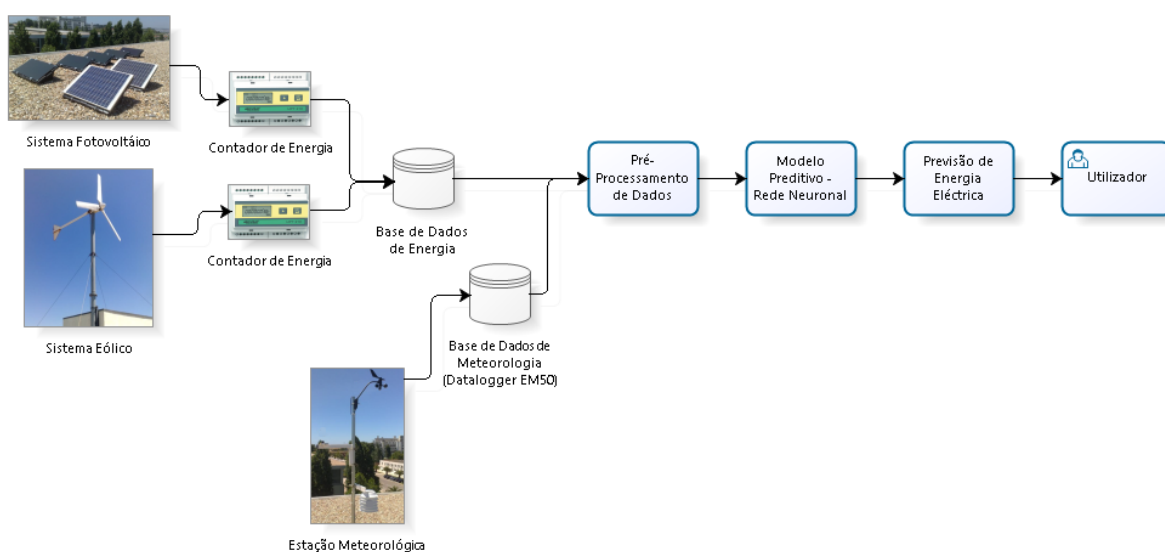


Figura 3.1: Arquitectura de alto nível.

Como se pode verificar na Figura 3.1, o sistema é composto principalmente por:

- Sistema fotovoltaico;
- Sistema eólico;
- Estação meteorológica;
- Dois contadores de energia;
- Base de dados energéticos;
- Base de dados meteorológicos (Datalogger EM50);
- Modelo preditivo;

Com a produção de energia, medida pelos contadores de energia, e com a previsão meteorológica, realizada pela estação meteorológica, de pelo menos um ano, é possível criar um modelo preditivo.

3. METODOLOGIA ADOPTADA

Esse modelo, baseado em redes neuronais artificiais, irá fornecer uma aproximação do que se irá produzir nos diferentes meses dos anos seguintes consoante a meteorologia de cada mês em que se pretende fazer a previsão. Os dados anuais presentes nas bases de dados respectivas são sujeitos a um pré-processamento para que as condições sejam as melhores possíveis para a aprendizagem do modelo em questão. Esse pré-processamento é feito a partir de um filtro, cujo tipo irá ser determinado mais adiante, e da análise em componentes principais que irá reduzir o número de variáveis à entrada do modelo e também o número de amostras dessas mesmas variáveis.

Após realizado o pré-processamento, os dados resultantes são usados para treinar uma rede neuronal para cada mês do ano, com duas possíveis estruturas, podendo assim obter-se o modelo final constituído por 12 redes neuronais.

Por fim, com o modelo desenvolvido e treinado, este será utilizado para prever a produção mensal e anual de energia solar e eólica, caso se tenha a previsão meteorológica do mês ou do ano que se pretende.

3.1.2 Obtenção de Dados

A obtenção de dados para desenvolver e testar este tipo de algoritmo passa por várias fases. Em primeiro é preciso fazer a recolha dos dados e depois é necessário realizar uma selecção e um tratamento dos mesmos para se trabalhar apenas com os dados necessários e no melhor estado para se desenvolver e testar o algoritmo.

Medição e Recolha de Dados

Em relação à medição da produção de energia eléctrica a partir do sistema fotovoltaico e eólico, esta é feita a partir de dois contadores, um para cada sistema. Esses valores são posteriormente enviados para a base de dados de energia e colocados na forma de ficheiros de texto com um formato específico. Os dados correspondentes à produção fotovoltaica são designados pela porta 6 e os correspondentes à produção eólica são designados por porta 7. Desta forma é possível distinguir as duas produções.

Já para a estação meteorológica, os dados são lidos pelo Datalogger EM50 a partir de 5 sensores de forma a medir a Radiação Solar, a Temperatura, a Velocidade do Vento, a Direcção do Vento e a Velocidade das Rajadas de Vento. Esta informação é colocada na forma de ficheiros *Comma-Separated Values* (CSV) com um formato específico, mas apenas serão consideradas 4 das 5 variáveis para o modelo. A variável que não será utilizada é a Velocidade das Rajadas de Vento.

Reestruturação

Como os ficheiros de texto presentes na base de dados de energia, não se encontram com a melhor organização para serem trabalhados a partir do programa *Microsoft Office Excel* e *Matlab* então é necessário fazer uma reestruturação.

Para tal desenvolveu-se um algoritmo em linguagem Java para ler toda a informação existente nos ficheiros e reescrevê-la novamente mas no formato CSV. Assim todos os dados que se pretendem utilizar poderão ser importados e posteriormente exportados no mesmo formato pelos programas anteriormente indicados. O diagrama da Figura 3.2 exemplifica a reestruturação dos ficheiros.




Figura 3.2: Reestruturação dos ficheiros de dados.

Recolha da Energia Produzida e da Meteorologia de 2013

Após feita a reestruturação dos ficheiros estes foram importados para o programa *Matlab* e como os ficheiros continham informação a mais para o pretendido, apesar de reestruturados, foi necessário realizar um tratamento diferente. Como nem todas as variáveis existentes nos ficheiros de texto, iriam ser consideradas para a construção deste modelo, desenvolveu-se um código em Matlab que realiza apenas a leitura das variáveis que se pretendem utilizar. Este código faz apenas a leitura dos valores obtidos pela porta 6, do sistema fotovoltaico, e pela porta 7, do sistema eólico, a uma determinada data e hora. Tendo os intervalos de tempo em que a produção é registada, o mesmo código selecciona a meteorologia para esses intervalos de tempo de forma a ter-se as condições meteorológicas que permitiram a produção correspondente. Desta forma é feita a selecção dos dados para cada mês do ano 2013 a utilizar para a construção do modelo preditivo. Poderá observar-se esta fase de forma resumida na Figura 3.3.

3. METODOLOGIA ADOPTADA

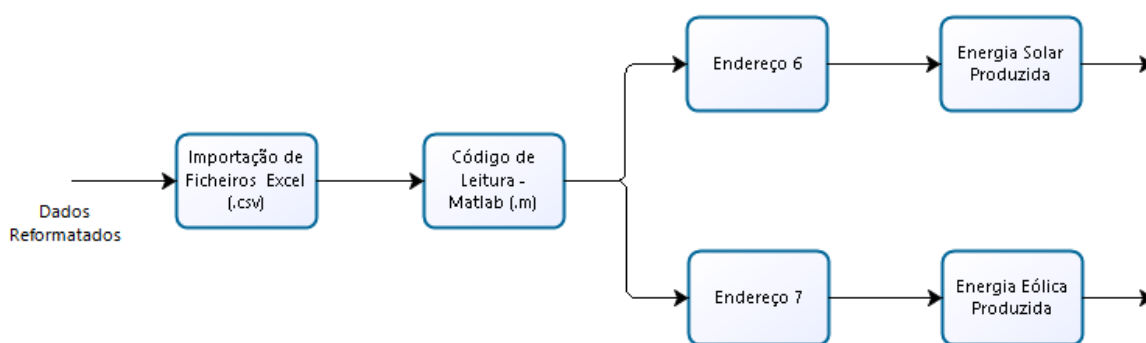


Figura 3.3: Leitura da energia produzida.

Geração de Meteorologia para 2014

Sendo os dados de 2013 a base para o desenvolvimento e construção do modelo preditivo com redes neurais, também é necessário ter dados que permitam testar a eficácia do modelo para as variações das condições meteorológicas ao longo dos anos. Para que tal seja possível usam-se os dados meteorológicos de 2013, e com o auxílio do programa *Microsoft Office Excel*, para os mesmos intervalos de tempo, calculam-se variações entre 75% e 125% para se obterem condições meteorológicas diferentes de 2013 para 2014. Não se consideram dados reais obtidos da estação meteorológica em 2014 devido a alterações efectuadas na base de dados, afectando os intervalos de tempo que se pretendiam trabalhar, e também devido a avarias existentes ao longo do ano perdendo assim uma quantidade significativa de dados necessários para testar o modelo.

Geração de Energia Produzida para 2014

Devido ao mesmo problema indicado no ponto anterior, não existe a possibilidade de se obter a energia real produzida ao longo do ano 2014. De forma a contornar o problema usam-se os dados de 2013 seleccionados e ao relacionar-se as variáveis de entrada com a energia produzida por cada sistema, fotovoltaico e eólico, criam-se 2 superfícies de aproximação. Para a obtenção dessas curvas considera-se que apenas a Radiação Solar e a Temperatura afectam a produção solar e que apenas a Velocidade e Direcção do Vento afectam a produção eólica. Após obtidas essas superfícies, usando os dados meteorológicos gerados da forma descrita no ponto anterior, é possível obter uma aproximação da energia produzida para as condições meteorológicas de 2014 geradas.

Os diagramas apresentados nas figuras 3.4 e 3.5 exemplificam os passos durante esta fase.

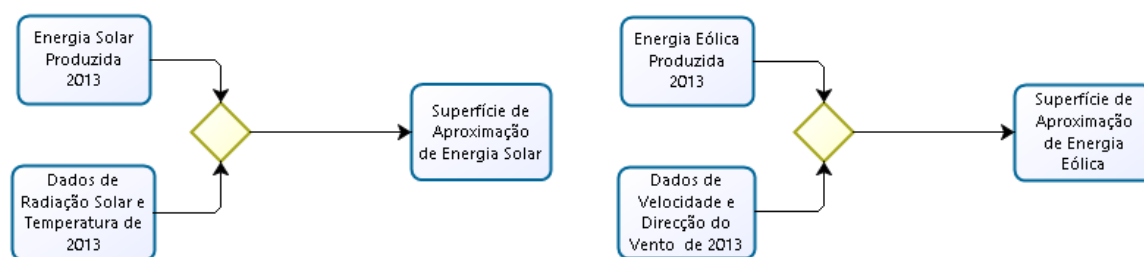


Figura 3.4: Superfícies de aproximação.



Figura 3.5: Obtenção da energia produzida em 2014.

3.1.3 Selecção de Dados

Quando existe um número elevado de amostras pode existir muito ruído que afecte o desempenho do modelo. Para evitar isso uma das coisas que se pode fazer é reduzir o número de amostras.

Redução de Número de Amostras

Para que se pudesse reduzir o número de amostras desenvolveu-se um código que permite fazer uma selecção de parte dos dados tanto de energia como das condições meteorológicas no mesmo intervalo de tempo. Esta selecção foi feita considerando um intervalo entre amostras muito superior ao existente, mantendo a relação entre as condições meteorológicas e a energia produzida para essas condições. Assim, com um número de amostras inferior por variável, tanto de entrada como de saída, o modelo terá padrões mais estáveis para treinar e posteriormente para testá-lo.

3.1.4 Definição de Número de Entradas e Saídas

Antes de se começar a desenvolver o modelo preditivo baseado em redes neuronais artificiais é necessário definir o número de entradas a usar no modelo para se obter a previsão, com ou sem amostras de atraso, e também o número de saída, ou seja, o número de variáveis que se pretende prever com

3. METODOLOGIA ADOPTADA

o modelo construído. Tal como foi referido neste capítulo em Processo, a partir do documento [15], é necessário considerar no mínimo 1 semana para planeamento de recursos e para isso optou-se por definir 7 entradas em que o atraso máximo considerado irá ser de 3 semanas, permitindo assim prever apenas a última semana do mês que se pretende.

As variáveis de entrada serão a Radiação Solar, a Temperatura, a Velocidade do Vento e a Direcção do Vento. Desta forma, a matriz de entrada nas Redes Neurais Artificiais será uma matriz do tipo M linhas e 32 colunas, onde M é o número de amostras por variável com o atraso definido. Sabendo que cada amostra corresponde a, aproximadamente, 5 minutos consideram-se os seguintes atrasos para cada uma das variáveis: 1 dia, 1 semana, 1 semana e 2 dias, 1 semana e 5 dias, 2 semanas e 1 dia, 2 semanas e 4 dias, e 3 semanas. Para a primeira coluna de cada variável considerou-se a amostra do momento. Já a saída, ou seja, a previsão do modelo a obter será apenas a totalidade da energia produzida pelos dois sistemas. Considerou-se o total produzido pelos sistemas como uma saída porque o padrão da previsão do modelo é muito semelhante ao da previsão da produção de energia solar, alterando-se apenas a amplitude ao somar-se a energia eólica produzida à energia solar.

3.1.5 Aplicação de Filtro

Considerando o estudo realizado no Estado de Arte em Pré e Pós-Processamento de Dados (Capítulo 2.2), para que o modelo receba os dados nas melhores condições possíveis, para o seu treino e posteriormente para ser testado, após a selecção dos dados e definição das entradas e saídas é necessário realizar a filtragem dos mesmos. Para tal aplicam-se os 3 tipos de filtros estudados, de forma a perceber o tipo que se adequa melhor à situação. Os 3 tipos de filtros a testar são: o Filtro Passa-baixo de primeira Ordem, o Filtro de Média Móvel e o Filtro *Savitzky-Golay*.

Para definir o melhor Filtro Passa-baixo de primeira ordem para o pretendido varia-se a constante α na equação 2.13 de forma a ver qual o valor que permite uma melhor filtragem dos dados sem que estes percam o seu formato, evitando assim a perda de informação.

Para escolher o melhor Filtro de Média Móvel varia-se o tamanho da janela deslizante onde se pretende realizar a média das amostras sem perder o formato original dos dados de entrada, e eliminando apenas o ruído existente.

Já para o Filtro *Savitzky-Golay*, a forma de escolher o melhor filtro é variar a ordem da aproximação a realizar entre amostras e também o número de amostras que se pretende preservar como momentos altos.

Após ser escolhido o melhor filtro de cada tipo, resta saber qual o melhor entre os três escolhidos. Para tal, aplica-se cada um deles a um conjunto de amostras que irá dar entrada no modelo preditivo, e aquele que apresentar um menor erro e uma maior semelhança ao conjunto de amostras original será o filtro a usar.

O diagrama apresentado na figura 3.6 indica a parte do sistema onde o filtro é aplicado.




Figura 3.6: Filtragem dos dados.

3.1.6 Normalização de Dados Filtrados

Após a aplicação do filtro, antes de se aplicar o processo de Análise em Componentes Principais, é necessário normalizar os dados filtrados. A normalização será feita no intervalo $[0, 1]$. Assim a PCA será aplicado da melhor forma.

Esta normalização será feita para as amostras que darão entrada no modelo, usando algumas linhas de código em *Matlab*, e também será aplicada às amostras de energia produzida de forma a poder-se comparar a previsão com os dados reais, testando assim a capacidade do modelo desenvolvido. Com a normalização realizada, é possível aplicar o processo PCA como mostra a figura 3.7.

3.1.7 Análise em Componentes Principais

A última fase, antes de se construírem as Redes Neurais Artificiais do modelo preditivo, é a aplicação do processo Análise em Componentes Principais.

Este processo tem como objectivo reduzir o número de entradas e amostras por entrada, e para tal é necessário analisar a matriz de componentes principais e verificar qual o número de componentes mais adequado a usar nas redes de forma a não perder informação importante.

Assim, para definir o número de componentes a utilizar é necessário verificar qual a percentagem de informação que é apresentada por cada número de componentes.

A figura 3.7 representa as fase da Normalização e da Análise em Componentes Principais.

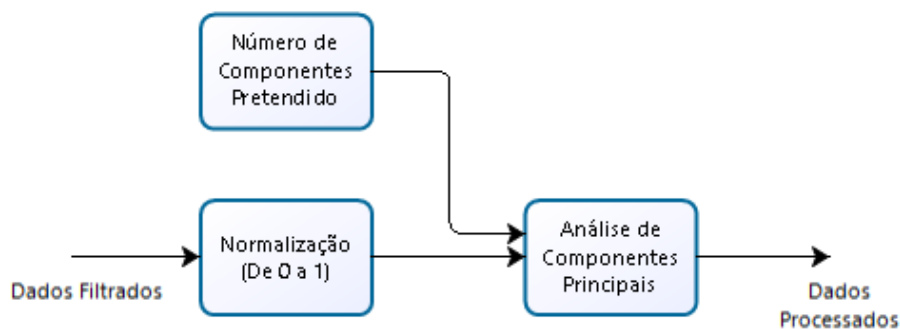


Figura 3.7: Normalização e Análise em Componentes Principais.

3.1.8 Definição da Estrutura da Rede Neuronal

Depois de se ter todos os dados processados nas melhores condições para utilizar no modelo preditivo, é preciso definir a estrutura da RNA. Duas das estruturas possíveis e analisadas nesta dissertação são:

- Com 1 camada intermédia;
- Com 2 camadas intermédias.

Estas duas estruturas irão ser descritas nos pontos seguintes.

Uma Camada Intermédia

A RNA constituída apenas por uma camada intermédia, representada na figura 3.8, é uma estrutura simples mas que poderá dar bons resultados. Neste caso, todas as 32 entradas irão dar entrada na mesma camada intermédia com os respectivos pesos e polarizações, não sendo diferenciados os 2 sistemas existentes, o sistema fotovoltaico e eólico. Esta camada intermédia será representada pela função *tansig* (tangente hiperbólica) e por um número de neurónios a definir, uma vez que se pretende o mínimo número de neurónios mas com o menor erro possível na previsão. A função escolhida é a *tansig* por ser a função mais utilizada para reconhecimento de padrões, que é o que se pretende com este algoritmo. Com esta função a saída desta camada será obtido com valores entre -1 e 1.

Após a passagem pela camada intermédia, a saída dessa camada, com o seu respectivo peso, irá dar entrada na camada de saída definida pela função *purelin* (linear) e o seu número de neurónio é obtido pela própria rede, consoante o que pretender à saída da RNA. Por fim, com a passagem pela camada de saída obtêm-se os resultados do treino da rede e se for bem sucedido ter-se-á uma das possíveis redes neuronais.

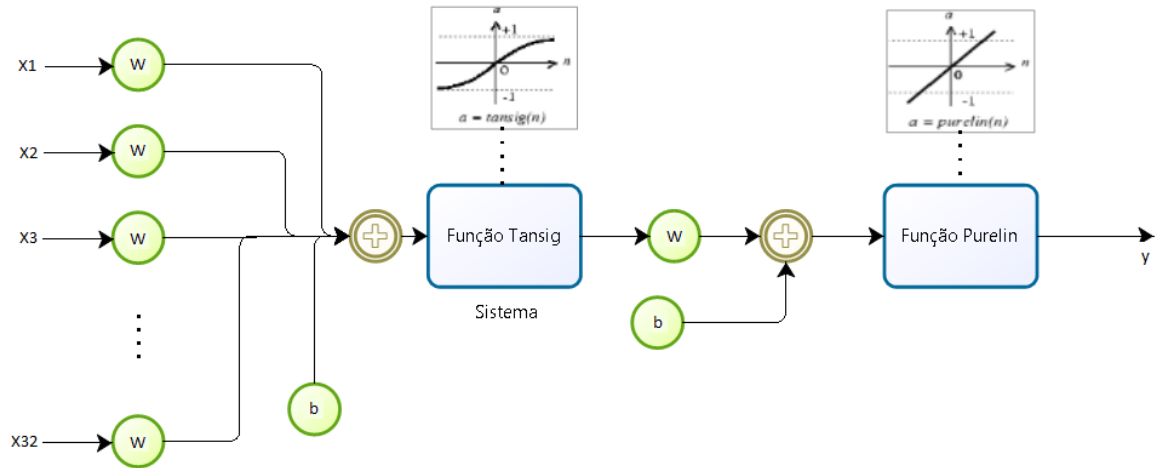


Figura 3.8: RNA com 1 camada intermédia.

Na Figura 3.8, $X_1, X_2, X_3 \dots X_{32}$ são os dados meteorológicos considerados para o treino e previsão da rede com os atrasos indicados no capítulo 3.1.4, W são os pesos respectivos de cada entrada, b as polarizações correspondentes, Sistema a camada intermédia, Função *Purelin* a camada linear de saída e y a energia prevista.

Duas Camadas Intermédias

A RNA constituída por duas camadas intermédias, representada na figura 3.9, é uma estrutura um pouco mais complexa mas que também poderá dar bons resultados. Neste caso, as 32 entradas irão estar divididas pelas duas camadas intermédias. As 16 entradas correspondentes à Radiação Solar e à Temperatura irão dar entrada numa das camadas, sendo essa a camada que representa o sistema fotovoltaico, e as restantes 16 entradas correspondentes à Velocidade e Direcção do Vento irão dar entrada na segunda camada que representa o sistema eólico. Desta forma tem-se ambos os sistemas existentes diferenciados, considerando que a Radiação Solar e a Temperatura são as únicas variáveis que afectam a produção de energia solar e que a Velocidade e Direcção do Vento são as únicas a influenciar a produção de energia eólica. Ambas as camadas intermédias serão representadas pela função *tansig* (tangente hiperbólica) e por um número de neurónios a definir, uma vez que se pretende o mínimo número de neurónios mas com o menor erro possível na previsão, tal como para a RNA com uma camada intermédia. A função escolhida é a *tansig* por ser a função mais utilizada para reconhecimento de padrões, que é o que se pretende com este algoritmo. Com esta função a saída destas duas camadas será obtida com valores entre -1 e 1.

Depois da passagem pelas camadas intermédias, as saídas dessas camadas, com os seus respectivos pesos, serão somadas dando entrada na camada de saída definida pela função *purelin* (linear) e o seu número de neurónios é obtido pela própria rede, consoante o que pretender à saída da RNA.

3. METODOLOGIA ADOPTADA

Por fim, com a passagem pela camada de saída obtêm-se os resultados do treino da rede e se for bem sucedido ter-se-á uma das possíveis redes neuronais, sendo assim possível concluir qual a melhor estrutura comparando com a RNA com uma camada intermédia.

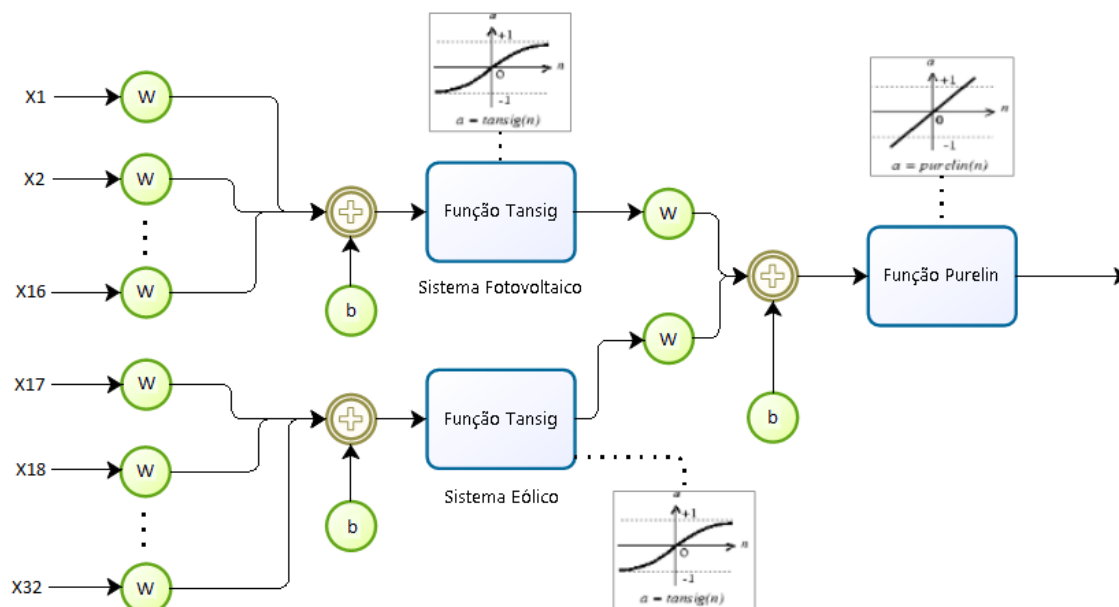


Figura 3.9: RNA com 2 camadas intermédias.

Na Figura 3.9, $X1, X2 \dots X16$ são os dados meteorológicos que caracterizam o sistema fotovoltaico, Temperatura e Radiação Solar, com os seus respectivos atrasos indicados no capítulo 3.1.4, $X17, X18 \dots X32$ os dos dados meteorológicos que caracterizam o sistema eólico, Velocidade e Direcção do Vento, com os seus respectivos atrasos também indicados no capítulo 3.14, considerados para o treino e previsão da rede. W são os pesos respectivos de cada entrada, b as polarizações correspondentes, Sistema Fotovoltaico e Sistema Eólico as camadas intermédias, Função *Purelin* a camada linear de saída e y a energia prevista.

3.2 Sinopse

Neste capítulo foi abordado o processo realizado ao longo da dissertação tal como a metodologia adoptada. Também foram descritas todas as fases necessárias para a criação do algoritmo de previsão de produção de energia eléctrica através de fontes de energia renováveis.

As fases foram desde a reestruturação dos ficheiros que continham as informações necessárias para a construção do algoritmo, até ao pré-processamento de dados e terminando com a definição e construção da estrutura da RNA.

CAPÍTULO 4

Treino e Validação dos Modelos

4.1	Método de Validação	37
4.2	Geração de Dados Energéticos para 2014	38
4.3	Resultado dos Dados Filtrados	39
4.4	Resultados Pós-PCA	43
4.5	Treino da Rede Neuronal	44
4.5.1	Uma Camada Intermédia	44
4.5.2	Duas Camadas Intermédias	48
4.6	Teste da Rede Neuronal	50
4.6.1	Uma Camada Intermédia	51
4.6.2	Duas Camadas Intermédias	53
4.7	Sinopse	54

Neste capítulo serão abordados os métodos de validação de resultados utilizados nesta dissertação e serão apresentados e analisados todos os resultados obtidos com o algoritmo desenvolvido.

4.1 Método de Validação

Para se validar os resultados obtidos nesta dissertação foram utilizados diferentes métodos de validação.

Para que fosse possível, após desenvolvido o modelo preditivo, testar a eficiência do mesmo, e devido à falta de dados, foi necessário gerar os dados de energia para 2014. Para tal, criaram-se superfícies de aproximação a partir dos dados meteorológicos e de energia do ano 2013, em que com dados meteorológicos de 2014 se obtém uma aproximação da energia produzida no ano 2014.

De forma a escolher o melhor filtro a utilizar no pré-processamento seleccionou-se um pequeno conjunto de dados meteorológicos que descreve, aproximadamente, o padrão ao longo do ano, e decidiu-se aplicar

4. TREINO E VALIDAÇÃO DOS MODELOS

vários filtros dos 3 tipos descritos no Estado de Arte. O filtro que descrever melhor o padrão dos dados, sem perder informação importante, será o filtro a utilizar no pré-processamento.

Depois de escolhido o filtro é necessário saber qual o número de componentes principais que se pretende obter com o processo PCA analisando qual apresentará uma percentagem de informação disponibilizada suficiente que permita ter um bom desempenho nas RNAs. Para tal, o número de componentes obtido pelo PCA poderá ser entre 1 e 32 componentes.

Após terminado o pré-processamento de dados, com o filtro e o número de componentes pós-PCA das RNAs definidos, falta validar as estruturas das RNAs construídas. Para isso será realizado o treino com os dados mensais do ano 2013 para diferentes números de neurónios na(s) camada(s) intermédia(s) e será escolhido o número de neurónios mais adequado para cada uma das camadas. O número de neurónios que apresentar um menor *Mean Squared Error* (MSE), o mais próximo possível de 0, e uma correlação mais próxima dos 100% será o escolhido para constituir a Rede Neuronal Artificial (RNA). Em seguida, já com as RNAs definidas, tanto com 1 como 2 camadas intermédias, é realizado o teste para os dados mensais do ano de 2014, de forma a que se consiga verificar a adaptabilidade das RNAs conforme as alterações meteorológicas.

Por fim, com todos os testes realizados será possível retirar as conclusões necessárias para a escolha da estrutura mais adequada da RNA para a previsão de produção de energia eléctrica através de fontes de energia renováveis.

4.2 Geração de Dados Energéticos para 2014

Devido à falta de dados para testar o modelo preditivo, como já foi referido anteriormente, foi necessário recorrer a superfícies de aproximação tanto para o sistema solar como para o sistema eólico. Utilizando os dados meteorológicos e energéticos do ano 2013, criaram-se as seguintes superfícies de aproximação:




Figura 4.1: Superfície de aproximação para a energia solar.




Figura 4.2: Superfície de aproximação para a energia eólica.

Como se pode observar, para o caso da energia solar representado na figura 4.1, a produção é linear, ou seja, quanto maior for a radiação incidente nos painéis e quanto maior for a temperatura, maior será a energia produzida, sendo esta limitada pela potência máxima dos painéis solares utilizados. Também se pode observar que a radiação solar tem uma maior influência na energia produzida devido a uma maior variação de energia ao longo do eixo correspondente à radiação solar.

Para o caso da energia eólica representado na figura 4.2, a aproximação da produção calculada é apenas uma média da produção de energia que se obteve em 2013, visto que o intervalo de valores da velocidade do vento é pequeno. Assim, com o uso da meteorologia de 2014 gerada, da forma como foi indicada no capítulo 4.2, e a partir destas superfícies criadas obteve-se uma aproximação da energia produzida para a meteorologia correspondente.

Após obtidos todos os dados necessários para o desenvolvimento e teste do modelo preditivo foi possível avançar para a parte seguinte que trata do pré-processamento de dados.

4.3 Resultado dos Dados Filtrados

Os tipos de filtros a serem apresentados e comparados são os tipos descritos no Estado de Arte. Os filtros em questão são o Filtro Passa-baixo de primeira ordem, o Filtro de Média Móvel e o Filtro *Savitzky-Golay*.

Em primeiro lugar, para o Filtro Passa-baixo de primeira ordem variou-se o coeficiente β entre 0,15 e 0,35 podendo-se escolher assim o melhor dos filtros Passa-baixo. Considerando os dados de produção de aproximadamente um dia, obtiveram-se para os diferentes valores de β os seguintes resultados:

4. TREINO E VALIDAÇÃO DOS MODELOS




Figura 4.3: Comparação entre diferentes Filtros Passa-baixo de primeira ordem.

Como é possível verificar o valor mais indicado para este tipo de filtro, sem se perder informação dos dados importantes, é o que tem um β de 0,35. Também é possível observar que quanto mais pequeno for o valor de β , mais perto da unidade estará o coeficiente α e maior será a filtragem realizada pelo filtro. Para um β de 0,15 o efeito do filtro já é muito elevado levando a alguma perda de informação que poderá ser importante.

Em segundo lugar, para o tipo de Filtro de Média-Móvel serão comparados diferentes tamanhos de janelas de amostras, sendo cada amostra correspondente a 5 minutos de um dia, em que se realizará a média. Mais uma vez o que apresentar o padrão mais semelhante aos dados seleccionados será o escolhido deste tipo. Os resultados obtidos para os diferentes tamanhos de janelas são:




Figura 4.4: Comparação entre diferentes Filtros de Média Móvel.

Para este caso, ao observar-se a figura 4.4, verifica-se que o tamanho mais indicado para este tipo de filtro é o filtro com um tamanho de janela igual a 2, visto que elimina parte dos picos de ruído mantendo o formato do sinal.

Ao observar-se os gráficos também se pode concluir que quanto maior for a janela de amostras sobre a qual se aplica a média, maior será o efeito do filtro tal como era esperado.

Em terceiro lugar, para o tipo de Filtro *Savitzky-Golay* decidiu-se usar aproximações de terceira e quarta ordem, mas para diferentes números de amostras a aproximar obtêm-se diferentes resultados.

Os resultados obtidos para os diferentes números de amostras são apresentados nas Figuras 4.5 e 4.6.




Figura 4.5: Comparação entre diferentes Filtros *Savitzky-Golay* de terceira ordem.




Figura 4.6: Comparação entre diferentes Filtros *Savitzky-Golay* de quarta ordem.

4. TREINO E VALIDAÇÃO DOS MODELOS

Neste caso, ao observar-se a figura 4.6, verifica-se que o número de amostras para este tipo de filtro para aproximações, tanto de terceira como de quarta ordem, a usar é 11. Como se pode observar ambos perdem parte do formato original do sinal mas acabam por reduzir o número de picos de ruído existente, o que para 5 não era realizado com tanto sucesso. Com a semelhança existente entre a terceira e quarta ordem de aproximação, optou-se pelo filtro de terceira ordem por ser o filtro menos complexo devido a ter uma ordem mais baixa.

Por fim, sabendo o filtro de cada tipo mais adequado para o padrão que se pretende filtrar, é possível realizar uma comparação entre esses 3 e escolher o que melhor se adequa. Comparando os 3 filtros escolhidos:




Figura 4.7: Comparação entre os 3 melhores filtros escolhidos.

Observando a figura 4.7, conclui-se que o filtro mais indicado para o padrão a filtrar é o filtro *Savitzky-Golay* de terceira ordem com um número de amostras igual a 11. Optou-se por este por ser dos 3 filtros aquele que obtém variações mais suaves quase sem a formação de picos, o que poderá ser prejudicial para as RNAs.

4.4 Resultados Pós-PCA

Depois de realizada a filtragem passa-baixo, segue-se o processo PCA. Para se saber o número de componentes principais mais indicado a obter no PCA para o treino das RNAs é necessário verificar aquele que apresenta os melhores resultados.

Assim, para cada mês calculou-se a matriz de valores singulares e analisaram-se os valores obtidos. Para tal, construiu-se um gráfico, relativo ao mês de Janeiro, onde se pode verificar a percentagem de informação disponibilizada nos resultados do PCA por cada número de componentes. A percentagem para o número de componentes corresponde à soma dos valores singulares dos números de componentes anteriores. Em que o total para o máximo número de componentes é 1 (100 %).




Figura 4.8: Percentagem de informação obtida por número de componentes após o PCA.

Considerando que para a estrutura com duas camadas intermédias apenas é possível ter um número par de componentes e observando o gráfico representado na figura 4.8, é possível concluir que um dos números de componentes mais indicado para o mês de Janeiro é 10, que disponibiliza 96,4% da informação do sinal.

Também se observou, ao realizar o PCA para os dados dos restantes meses do ano, que os valores singulares para cada número de componentes é diferente para cada um dos meses. Sendo assim realizou-se o mesmo processo para obtenção dos gráficos para todos os meses do ano. Devido ao elevado número de gráficos, e uma vez que o seu formato é semelhante para todos os meses, variando apenas os valores singulares para cada número de componentes, decidiu-se apresentar apenas uma tabela com o número de componentes a obter do PCA e a percentagem de informação disponibilizada por esse número de componentes para cada um dos meses do ano.

Tabela 4.1: Número de componentes com percentagem de informação disponibilizada pelo PCA.

Mês	Nº de Componentes	Informação Disponibilizada (%)
Janeiro	10	96,4
Fevereiro	12	97,5
Março	12	97,7
Abril	10	98,1
Maiο	10	97,4
Junho	10	98,1
Julho	10	97,8
Agosto	10	97,6
Setembro	10	97,4
Outubro	8	97,7
Novembro	8	100
Dezembro	8	99,7

Teve-se como preferência os números de componentes pares e que apresentassem uma percentagem entre os 95 e os 100 %. Desta forma, o mesmo número de componentes é aplicável a ambas as estruturas de RNAs estudadas. Para o mês de Novembro e Dezembro, por terem uma percentagem de disponibilidade de informação de 100 % e de 99,7 %, não se optou por um número de componentes inferior porque para um número de componentes par inferior, o valor aproximava-se dos 90 %, afastando-se assim do intervalo de percentagens tido como preferência.

4.5 Treino da Rede Neuronal

Neste ponto serão desenvolvidas e treinadas as duas estruturas de RNAs definidas no Capítulo 3.1.8. Em primeiro lugar será realizado o treino da RNA com uma camada intermédia, tal como a análise dos resultados, e depois será realizado o treino da RNA com duas camadas intermédias e também a análise dos resultados obtidos.

4.5.1 Uma Camada Intermédia

Para a RNA com uma camada intermédia, com o formato indicado na figura 3.8, após realizado o pré-processamento com o filtro *Savitzky-Golay* e o processo PCA para os números de componentes indicados na Tabela 4.1, falta definir o número de neurónios ideal para a camada intermédia.

De forma a obter esse número realizaram-se diversos treinos na RNA para diferentes números de

neurónios, entre 1 e 15, e posteriormente gerou-se um gráfico de barras que indica o erro de predição obtido para cada número de neurónios da camada.

O desempenho obtido para cada número de neurónios foram os seguintes:




Figura 4.9: Resultado do treino da RNA com 1 camada intermédia (Janeiro) - Performance vs Nº de Neurónios.

Considerando que o número de neurónios afecta a complexidade do algoritmo, torna-se necessário encontrar um equilíbrio entre o número de neurónios e o erro mínimo obtido.

Na figura 4.9 observa-se que até 4 neurónios o erro diminui mas a partir desse número, o erro obtido pela rede estabiliza, aumentando apenas a complexidade da rede.

Apesar de terem valores semelhantes, após algumas simulações, verificou-se que o número de neurónios que apresenta a melhor previsão é 6, sendo assim o mais indicado para o pretendido no mês de Janeiro. O mesmo processo foi repetido para os restantes meses do ano e definiu-se um número de neurónios para cada mês.

De seguida irão ser apresentados os resultados do treino para a RNA com uma camada intermédia com 6 neurónios, para o mês de Janeiro, seguido de uma tabela com os neurónios para os restantes meses do ano.

4. TREINO E VALIDAÇÃO DOS MODELOS

Resultado do Treino

Com o número de neurónios definido e considerando apenas os dados do mês de Janeiro de 2013, os resultados do treino desta RNA obtidos, com e sem aplicação de filtro à saída da rede e após invertido o PCA e feita a desnormalização dos dados, foram os seguintes:




Figura 4.10: Resultado do treino da RNA com 1 camada intermédia (2013) - 4ª semana (1 amostra = 5 minutos).




Figura 4.11: Resultado filtrado do treino da RNA com 1 camada intermédia (2013) - 4ª semana (1 amostra = 5 minutos).

A figura 4.10 apresenta o resultado do treino com a energia produzida esperada e prevista para o mês de Janeiro de 2013, sem que esta última esteja filtrada, e a figura 4.11 apresenta o mesmo resultado mas em que a energia produzida prevista se encontra filtrada.

Pode-se observar que a previsão, a vermelho, acompanha aproximadamente a produção esperada, com alguma oscilação principalmente nas zonas de maior frequência. Nas zonas em que a produção é constante a previsão acompanha melhor a produção esperada. Parte das oscilações existentes são eliminadas, ou pelo menos, suavizadas com aplicação do filtro, como mostra a figura 4.11.

O mesmo procedimento foi feito para os restantes meses do ano, em que o desempenho (MSE) e a correlação obtidos entre a produção esperada e a prevista para todos os meses do ano 2013 com a aplicação de filtro são apresentados de seguida na tabela 4.2.

Tabela 4.2: Desempenho e correlação mensal dos treinos das RNAs com 1 camada intermédia.

Mês	Número de Neurónios	Desempenho (MSE)	Correlação (%)
Janeiro	6	0,0050	99,75
Fevereiro	7	0,0091	99,54
Março	7	0,0073	99,63
Abril	8	0,0087	99,57
Maio	7	0,0643	96,73
Junho	6	0,0299	98,50
Julho	6	0,0323	98,37
Agosto	9	0,0502	97,46
Setembro	6	0,0755	96,15
Outubro	10	0,0360	98,18
Novembro	8	0,1054	94,58
Dezembro	8	0,1743	90,87

Com os resultados obtidos é possível concluir que a média de número de neurónios anual é de aproximadamente 7. Verifica-se também um erro muito elevado para grande parte do ano, à excepção dos meses Janeiro, Fevereiro, Março e Abril, que apresentam um desempenho abaixo de 0,01, que se considera aceitável. O desempenho médio é de, aproximadamente, 0,0498, e a correlação média é de 97,44 %.

Estes valores de erro elevados devem-se à imprevisibilidade da meteorologia, que se altera constantemente, e também à qualidade dos dados utilizados.

4.5.2 Duas Camadas Intermédias

Já para a RNA com duas camadas intermédias, com o formato indicado na figura 3.9, após realizado o pré-processamento com o filtro *Savitzky-Golay* e o processo PCA para os números de componentes definidos no Capítulo 4.4, tal como para a RNA com uma camada intermédia, falta definir a combinação de neurónios ideal para as camadas intermédias.

De forma a obter esses números realizaram-se diversos treinos da RNA para diferentes números de neurónios, entre 1 e 15, para ambas as camadas intermédias para o mês de Janeiro. Devido ao elevado número de combinações de neurónios, não se gerou um gráfico de barras como foi feito para a RNA com uma camada intermédia mas analisou-se a matriz 15x15 dos desempenhos obtidos, e concluiu-se que a combinação que apresenta o melhor desempenho é a Camada do Sistema Fotovoltaico com 10 neurónios e Camada do Sistema Eólico com 8 neurónios.

Tal como anteriormente, considerando que o número de neurónios afecta a complexidade do algoritmo, foi necessário encontrar um equilíbrio entre a combinação do número de neurónios e o erro mínimo obtido.

Resultado do Treino

Com o número de neurónios definido e considerando apenas os dados do mês de Janeiro de 2013, os resultados do treino desta RNA obtidos, com e sem aplicação de filtro à saída da rede e após invertido o PCA e feita a desnormalização dos dados, foram os seguintes:




Figura 4.12: Resultado do Treino da RNA com 2 Camadas Intermédias (2013) - 4ª semana (1 amostra = 5 minutos).




Figura 4.13: Resultado filtrado do treino da RNA com 2 camadas intermédias (2013) - 4^a semana (1 amostra = 5 minutos).

Tal como foi realizado para a RNA com apenas uma camada intermédia, a figura 4.12 apresenta o resultado do treino com a energia produzida esperada e prevista, sem que esta esteja filtrada, e a figura 4.13 apresenta o mesmo resultado mas em que a energia produzida prevista se encontra filtrada. Pode-se observar que a previsão, a vermelho, acompanha aproximadamente a produção esperada com uma maior oscilação que a RNA com 1 camada intermédia, em que parte é eliminada com aplicação do filtro, como mostra a figura 4.13.

Esta oscilação acontece principalmente em zonas em que a produção é constante e isso poderá dever-se ao facto da RNA ter uma complexidade elevada, comparando com a RNA com uma camada intermédia. Já nas zonas em que a frequência é elevada, esta rede acompanha muito melhor o sinal esperado que a RNA com uma camada intermédia.

O mesmo procedimento foi feito para os restantes meses do ano, em que o desempenho (MSE) e a correlação entre a produção esperada e a prevista para todos os meses do ano 2013 com a aplicação de filtro são apresentados na tabela 4.3.

Tabela 4.3: Desempenho e correlação mensal dos treinos das RNAs com 2 camadas intermédias.

Camada	Camada 1 (Solar)	Camada 2 (Eólica)		
Mês	Nº de Neurónios	Nº de Neurónios	Desempenho (MSE)	Correlação (%)
Janeiro	10	8	0,0024	99,88
Fevereiro	10	9	0,0099	99,50
Março	9	10	0,0079	99,61
Abril	10	11	0,0052	99,74
Maio	10	9	0,0542	97,25
Junho	10	9	0,0205	98,97
Julho	10	12	0,0299	98,49
Agosto	10	9	0,0382	98,07
Setembro	10	9	0,0895	95,42
Outubro	9	9	0,0349	98,24
Novembro	9	9	0,0946	95,15
Dezembro	10	10	0,1550	91,93

Com os resultados obtidos é possível concluir que a média de número de neurónios anual é de aproximadamente 10, para a camada correspondente ao sistema fotovoltaico, e de 9, para a camada correspondente ao sistema eólico.

Verifica-se também um erro muito elevado para a grande parte do ano, à excepção dos meses Janeiro, Fevereiro, Março e Abril, que apresentam um desempenho abaixo de 0,01, que se considera aceitável. O desempenho médio é de, aproximadamente, 0,04518, e a correlação média é de 97,69 %.

Estes valores de erro elevado devem-se à imprevisibilidade da meteorologia, que se altera constantemente, e também à qualidade dos dados utilizados.

4.6 Teste da Rede Neuronal

De forma a testar a adaptabilidade e a eficiência das RNAs treinadas, realizaram-se testes de previsão das RNAs para meteorologia diferentes daquelas para as quais foram treinadas, mais precisamente utilizando a meteorologia gerada para 2014 tal como a energia produzida esperada correspondente.

Tal como os dados de 2013, os dados de 2014 também são obrigados a passar pelo mesmo tratamento no pré-processamento.

4.6.1 Uma Camada Intermédia

Resultados para 2014

Após ter-se processado os dados de 2014, estes são usados para realizar a previsão para esse mesmo ano. Considerando apenas os dados do mês de Janeiro de 2014, os resultados do treino desta RNA obtidos estão indicados nas Figuras 4.14 e 4.15.




Figura 4.14: Resultado do treino da RNA com 1 camada intermédia (2014) - 4ª semana (1 amostra = 5 minutos).




Figura 4.15: Resultado filtrado do treino da RNA com 1 camada intermédia (2014) - 4ª semana (1 amostra = 5 minutos).

4. TREINO E VALIDAÇÃO DOS MODELOS

Tal como foi apresentado para a RNA com apenas uma camada intermédia, na figura 4.14 observa-se o resultado do treino com a energia produzida esperada, sem que esta esteja filtrada, e na figura 4.15 observa-se o mesmo resultado mas em que a energia produzida esperada se encontra filtrada.

Também se observa que quando a produção é constante a previsão acompanha bem a energia produzida esperada, mas quando a frequência da energia produzida aumenta, esta já não acompanha tão bem tal como aconteceu no treino para os dados de 2013.

Os desempenhos (MSE) e as correlações para todos os meses do ano 2014 são apresentados na tabela 4.4.

Tabela 4.4: Desempenho e correlação mensal das RNAs com 1 camada intermédia do ano 2014.

Mês	Desempenho (MSE)	Correlação (%)
Janeiro	0,0090	99,55
Fevereiro	0,0184	99,12
Março	0,0127	99,41
Abril	0,0143	99,32
Maio	0,0306	98,35
Junho	0,0204	99,11
Julho	0,0224	98,88
Agosto	0,0194	98,98
Setembro	0,0544	97,46
Outubro	0,1245	93,50
Novembro	0,0578	97,56
Dezembro	0,0831	95,05

Tal como era esperado, após a análise dos resultados do treino para a RNA com uma camada intermédia, também existe erro muito elevado para grande parte do ano de 2014, à excepção do mês de Janeiro que apresenta um desempenho abaixo de 0,01, que se considera aceitável. Estes erros elevados devem-se ao agravamento dos problemas de oscilação analisados para o mês de Janeiro.

O desempenho médio obtido é de, aproximadamente, 0,03892, e a correlação média é de 98,02 %.

4.6.2 Duas Camadas Intermédias

Resultado para 2014

Tal como foi realizado para a RNA com uma camada intermédia, após ter-se processado os dados de 2014, estes são usados para realizar a previsão para esse mesmo ano. Considerando apenas os dados do mês de Janeiro de 2014, os resultados do treino desta RNA obtidos apresentam-se nas Figuras 4.16 e 4.17.




Figura 4.16: Resultado do treino da RNA com 2 camadas intermédias (2014) - 4ª semana (1 amostra = 5 minutos).




Figura 4.17: Resultado filtrado do treino da RNA com 2 camadas intermédias (2014) - 4ª semana (1 amostra = 5 minutos).

4. TREINO E VALIDAÇÃO DOS MODELOS

Na figura 4.16 observa-se o resultado do treino com a energia produzida esperada, sem que esta esteja filtrada, e na figura 4.17 observa-se o mesmo resultado mas em que a energia produzida esperada se encontra filtrada.

Também se observa que quando a frequência da energia produzida aumenta a previsão acompanha bem a energia produzida esperada, mas com a energia produzida constante, esta não acompanha tão bem tal como aconteceu no treino para os dados de 2013, devido à elevada complexidade da RNA.

Os desempenhos (MSE) e as correlações obtidas para todos os meses do ano 2014 são apresentados na tabela 4.5.

Tabela 4.5: Desempenho e correlação mensal das RNAs com 2 camadas intermédias do ano 2014.

Mês	Desempenho (MSE)	Correlação (%)
Janeiro	0,0077	99,61
Fevereiro	0,0190	99,10
Março	0,0142	99,33
Abril	0,0156	99,29
Maió	0,0380	97,97
Junho	0,0178	99,21
Julho	0,0242	98,79
Agosto	0,0265	98,62
Setembro	0,0565	97,33
Outubro	0,1303	93,22
Novembro	0,0655	97,36
Dezembro	0,0954	94,20

Tal como era esperado, após a análise dos resultados do treino para a RNA com duas camadas intermédias, também existe erro muito elevado para grande parte do ano de 2014, à excepção do mês de Janeiro que apresenta um desempenho abaixo de 0,01, que se considera aceitável.

Tal como para a RNA com duas camadas intermédias, estes erros elevados devem-se ao agravamento dos problemas de oscilação analisados para o mês de Janeiro.

O desempenho médio obtido é de, aproximadamente, 0,04256, e a correlação média é de 97,84 %.

4.7 Sinopse

Neste capítulo foram indicados todos os métodos de treino e de validação de resultados do modelo utilizados nesta dissertação. Foram também apresentados e analisados todos os resultados obtidos com o algoritmo desenvolvido.

CAPÍTULO 5

Conclusões e Trabalhos Futuros

5.1	Conclusões	55
5.2	Trabalhos Futuros	57

Neste último capítulo serão tiradas as conclusões face aos resultados obtidos ao longo desta dissertação e também serão apresentados possíveis trabalhos futuros na área.

5.1 Conclusões

Durante o desenvolvimento desta dissertação foi possível verificar que existem diversos métodos para realizar o pré-processamento de dados e que também existem vários tipos de modelos preditivos, entre eles redes neuronais artificiais, modelos difusos e modelos estatísticos.

Para a realização desta dissertação passou-se por diferentes fases. A primeira foi realizar o tratamento dos dados que eram fornecidos pela estação meteorológica e pelos contadores de energia. Para este tratamento desenvolveu-se um código na linguagem de programação Java, com o auxílio da aplicação *Microsoft Visual Studio*, de forma a reestruturar os ficheiros recebidos com os dados. Assim foi possível fazer uma leitura e análise inicial dos dados para que se pudesse definir os passos seguintes da dissertação.

Após ter-se os dados organizados e feita a análise inicial, optou-se por aplicar um pré-processamento dos dados para que estivessem nas condições necessárias para serem usados na construção do modelo. Este pré-processamento foi feito primeiro com a aplicação de um filtro definido após a análise de 3 tipos diferentes de filtros: o Filtro Passa-baixo de 1ª ordem, o Filtro de Média-Móvel e o Filtro *Savitzky-Golay*. A segunda fase do pré-processamento consistiu no processamento com PCA, sendo assim possível reduzir o número de variáveis/entradas a usar para treino da rede.

Com o pré-processamento terminado, usaram-se os dados resultantes para a construção de duas RNAs com estruturas diferentes. Uma com apenas uma camada intermédia, e uma mais complexa com duas

5. CONCLUSÕES E TRABALHOS FUTUROS

camadas intermédias de forma a distinguir os dois sistemas de produção.

Tendo sido realizado o treino das duas redes, testaram-se essas mesmas para prever a produção do ano a seguir ao ano para o qual foram treinadas.

Analisando os resultados obtidos, concluiu-se em relação aos filtros que independentemente do filtro que se aplique haverá sempre algumas "perdas" de informação, ou seja, o sinal acaba por perder a sua forma original. Para além do ruído, parte da sua forma original é perdida. Comparando os diferentes tipos de filtros, o filtro mais indicado para o pretendido foi o filtro *Savitzky-Golay*.

No PCA observou-se que quanto menor for o número de componentes que o modelo utiliza menor será a percentagem de informação disponibilizada pelo processo para o treino e teste da rede. De forma a utilizar o número de componentes mais adequado optou-se por escolher um número de componentes reduzido, ao analisar a matriz de valores singulares, que apresentasse uma percentagem entre os 95 e os 100 % de informação disponibilizada. Verificou-se também necessário aplicar o PCA de forma diferente para cada mês do ano, uma vez que a matriz de valores singulares varia de acordo com os dados utilizados. Com o pré-processamento definido, no treino das redes verificou-se que ambas apresentavam resultados problemáticos, cada uma em situações diferentes. Ao analisar-se os gráficos obtidos dos resultados dos treinos concluiu-se que quando a produção não varia muito, a RNA que melhor se adapta é a RNA com uma camada intermédia, mas quando existe grandes variações de produção de energia, a RNA que melhor se adapta é a RNA com duas camadas intermédias. A RNA com duas camadas intermédias é uma rede mais "nervosa" em situações em que a produção é aproximadamente constante, ou seja, a previsão varia muito em redor desses valores em vez de se manter igualmente constante, e a RNA com uma camada intermédia nas situações em que a energia produzida varia muito, acaba por realizar uma média entre o máximo e o mínimo dessas variações em grande parte da previsão.

A partir dos valores representados nas tabelas com os resultados dos treinos e dos testes às RNAs, concluiu-se também que a RNA com uma camada intermédia é a estrutura que apresentou uma melhor reacção à variação das condições meteorológicas do ano 2013 para o ano 2014, uma vez que apresentou um melhor desempenho médio e uma correlação média mais próxima dos 100 %.

Assim sendo, conclui-se que a RNA mais apropriada para o modelo pretendido na previsão de produção de energia eléctrica através de fontes de energia renováveis é a RNA com uma camada intermédia.

Os resultados obtidos não foram de encontro com as expectativas, concluindo assim que um modelo baseado em RNAs, pelo menos com as estruturas estudadas, não é o mais indicado para a previsão de produção de energia eléctrica através de fontes de energia renováveis no DEE da Faculdade de Ciências e Tecnologia, da Universidade Nova de Lisboa.

5.2 Trabalhos Futuros

Considerando os aspectos referidos nas conclusões, um dos trabalhos futuros propostos baseia-se num tratamento prévio de dados obtidos da estação meteorológica e dos contadores de energia do DEE, visto que os dados actualmente gerados não se encontram nas condições necessárias para serem trabalhados.

Outro trabalho futuro possível baseia-se na criação de uma aplicação onde se possa aceder a todos os dados gerados pela estação meteorológica e pelos contadores de energia, já com o tratamento anterior referido, e também onde se possa observar os consumos e produções de energia do departamento, tal como as suas previsões.

E outro possível trabalho futuro baseia-se na extensão do tempo de previsão de produção de energia do modelo preditivo, uma vez que o modelo apresentado se encontra limitado a uma semana de previsão.

Bibliografia

- [1] New World Encyclopedia. Dendrite. <http://www.newworldencyclopedia.org/entry/Dendrite>.
- [2] LaTeX. Diagram of an artificial neural network. <http://tex.stackexchange.com/questions/132444/diagram-of-an-artificial-neural-network>.
- [3] Filipe Tiago Martins Marques. Aplicação e comparação de metodologias de modelação à previsão de produção de energia eléctrica em centrais eólicas. Novembro 2011.
- [4] José García-Antón José Luis Guiñón, Emma Ortega and Valentín Pérez-Herranz. Moving average and savitzky-golay smoothing filters using mathcad. September 2007.
- [5] Duncan Fyfe Gillies. Lecture 15: Principal component analysis. *Department of Computing, Imperial College of London*.
- [6] Carlos Silva. Desenvolvimento de uma metodologia e ferramentas para a previsão de produção eléctrica em parques fotovoltaicos. Fevereiro 2012.
- [7] Hermínio Duarte Ramos. *Controlo Neuronal*. Departamento de Engenharia Electrotécnica, Faculdade de Ciências e Tecnologia.
- [8] R. Rojas. *Neural Networks: A Systematic Introduction*. Springer, Berlin, 1996.
- [9] Giebel G. Landberg L. Madsen-H. Joensen, A.K. and H.A. Nielsen. Un modello di valutazione della funzionalità protettiva del bosco per la pianificazione forestale: la componente stabilità dei versanti rispetto ai fenomeni franosi superficiali. *Italian Society of Silviculture and Forest Ecology*, December 2005.
- [10] NeuroSolutions. What is a neural network? <http://www.nd.com/welcome/whatisnn.htm>.
- [11] Hermínio Duarte Ramos. *Controlo Difuso*. Departamento de Engenharia Electrotécnica, Faculdade de Ciências e Tecnologia.
- [12] George Galanis George Kallos Akrivi Kaperon, Christos Stathopoulos. Wind power prediction based on numerical and statistical models. *Journal of Wind Engineering and Industrial Aerodynamics*, February 2012.
- [13] Sophocles J. Orfanidis. *Introduction To Signal Processing*. Prentice Hall International, 1996.
- [14] Cambridge University. *Numerical Recipes in C: The Art of Scientific Computing*. Cambridge University Press, 1988-1992.
- [15] Met Office. *Met Office Science Strategy*. 2010-2015.

